



**INSTITUTO POLITÉCNICO NACIONAL**

ESCUELA SUPERIOR DE INGENIERÍA MECÁNICA Y ELÉCTRICA  
SECCIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA  
A MEDIANO PLAZO EMPLEANDO UNA RED NEURONAL DE  
RETROPROPAGACIÓN

# TESIS

QUE PARA OBTENER EL GRADO DE:

MAESTRO EN CIENCIAS CON  
ESPECIALIDAD EN INGENIERÍA ELÉCTRICA.

PRESENTA:

**ING. GABRIEL ALLENDE SANCHO.**



MÉXICO, D.F.

DICIEMBRE DEL 2004



# INSTITUTO POLITECNICO NACIONAL COORDINACION GENERAL DE POSGRADO E INVESTIGACION

## ACTA DE REVISION DE TESIS

En la Ciudad de México, D. F. siendo las 12:00 horas del día 29 del mes de Junio del 2004 se reunieron los miembros de la Comisión Revisora de Tesis designada Por el Colegio de Profesores de Estudios de Posgrado e Investigación de la E. S. I. M. E. para examinar la tesis de grado titulada:

**“PRONOSTICO DE LA DEMANDA DE ENERGIA ELECTRICA A MEDIANO PLAZO EMPLEANDO UNA RED NEURONAL DE RETROPROPAGACION”**

Presentada por el alumno:

**ALLENDE**

Apellido paterno

**SANCHO**

materno

**GABRIEL**

nombre(s)

Con registro: 

0	2	1	4	4	7
---	---	---	---	---	---

Aspirante al grado de:

**MAESTRO EN CIENCIAS**

Después de intercambiar opiniones los miembros de la Comisión manifestaron **SU APROBACIÓN DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

### LA COMISION REVISORA

Director de tesis

DR. JAIME ROBLES GARCIA

DR. DANIEL OLGUIN SALINAS

M. EN C. MIGUEL ANGEL AVILA ROSALES

DR. RICARDO OCTAVIO MOTA PALOMINO

DR. DAVID ROMERO ROMERO

M. EN C. JESUS REYES GARCIA

EL PRESIDENTE DEL COLEGIO

DR. FLORENCIO SANCHEZ SILVA



SECCION DE ESTUDIOS DE POSGRADO E INVESTIGACION



# INSTITUTO POLITECNICO NACIONAL

COORDINACION GENERAL DE POSGRADO E INVESTIGACION

## CARTA CESION DE DERECHOS

En la Ciudad de México, Distrito Federal, el día 10 del mes de diciembre del año 2004, el que suscribe Ingeniero Gabriel Allende Sancho, alumno del Programa de Maestría en Ciencias Ingeniería Eléctrica con número de registro 021447, adscrito a la Sección de Estudios de Posgrado e Investigación de la ESIME Unidad Zacatenco, manifiesta que es autor intelectual del presente Trabajo de Tesis bajo la dirección del Dr. Jaime Robles García y cede los derechos del trabajo titulado: PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A MEDIANO PLAZO EMPLEANDO UNA RED NEURONAL DE RETROPROPAGACIÓN, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Éste puede ser obtenido escribiendo a las siguientes direcciones: [jarobles@ipn.mx](mailto:jarobles@ipn.mx), [aesq700324a@prodigy.net.mx](mailto:aesq700324a@prodigy.net.mx).

Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

---

Ing. Gabriel Allende Sancho.

## **DEDICATORIAS:**

### **PRIMERAMENTE A DIOS.**

*Por darnos la vida, la fuerza y la fe que nos mueve.*

### **EN MEMORIA DE.**

#### **MI PADRE**

*Quien ya no se encuentra entre nosotros y represento un símbolo a seguir en mi vida.*

### **ESPECIALMENTE A.**

#### **MI ESPOSA.**

*Con todo mi cariño por haber sido el apoyo incondicional para alcanzar este logro que también es de ella.*

### **A MIS HIJOS.**

*Oscar Gabriel y Maria Evelia, ya que representan para mi una gran inspiración que me motivo en la realización de esta empresa.*

### **A MI MADRE.**

*Por haber sido mi primera maestra, mi mejor amiga y a quien debo todo lo que soy.*

### **A MIS HERMANOS.**

#### **MIS TÍOS.**

#### **Y MIS COMPAÑEROS.**

*Por la amistad, compañerismo, apoyo y ayuda que cada uno de ellos supo dar en cada momento cuando fue necesitado.*

## **AGRADECIMIENTOS:**

**A LA**

**ESCUELA SUPERIOR DE INGENIERÍA  
MECÁNICA Y ELÉCTRICA,**

**DEL INSTITUTO POLITÉCNICO NACIONAL.**

**EN ESPECIAL A LA SECCIÓN DE ESTUDIOS DE  
POSGRADO E INVESTIGACIÓN:**

*Por haber brindado el espacio y la oportunidad de estudiar dentro de sus aulas para adquirir los conocimientos especializados que forman parte del programa de estudios de la maestría en ciencias en ingeniería eléctrica.*

**A MIS MAESTROS.**

*Por haberme guiado y brindarme su sabiduría y conocimientos para la culminación de mis estudios.*

**A MI ASESOR.**

**DR. JAIME ROBLES GARCÍA.**

*Por su acertada y valiosa dirección en la elaboración de esta tesis y por todo el apoyo y ayuda brindada a lo largo de mi carrera profesional.*

**A LOS MIEMBROS DE COMISIÓN REVISORA DE  
TESIS.**

*Dr. Daniel Olguín Salinas, Dr. David Romero Romero, Dr. Jaime Robles García, Dr. Ricardo Mota Palomino, M.C. Miguel Ángel Ávila Rosales y M.C. Jesús Reyes García, por el tiempo dedicado y por sus acertadas observaciones y recomendaciones para la depuración de este trabajo.*



**AGRADECIMIENTOS:**

**A LA:**

**SECRETARÍA DE LA DEFENSA NACIONAL  
DIRECCIÓN GENERAL DE MATERIALES DE GUERRA.**

*Por la oportunidad brindada para realizar estudios de posgrado,  
para mi desarrollo profesional, con los cuales alcanzaré un mejor  
desempeño en las tareas que me son encomendadas.*

**Y EN ESPECIAL A LA:  
ESCUELA MILITAR DE INGENIEROS**

***“CRISOL DE CIENCIA Y EL HONOR”***

*Por haber sido la institución que despertó en mí el hambre  
y la inquietud de buscar en la ciencia el conocimiento que  
solo se logra con el estudio y la dedicación.*

## Resumen

En esta tesis se presenta una técnica de redes neuronales artificiales (RNA) para realizar el pronóstico de la demanda de energía eléctrica a mediano plazo, comparando sus resultados contra las técnicas de regresión lineal y método autorregresivo. Por lo tanto, en este trabajo se busca encontrar que las RNA puedan minimizar la incertidumbre por conocer la demanda de energía eléctrica futura que se tendrá a mediano plazo.

La tarea de pronosticar la demanda de energía eléctrica, es conocer de la forma más precisa el suministro de energía eléctrica, utilizando factores propios del consumo. Esto involucra tener información confiable de los volúmenes aproximados de generación, así como de variables tales como, población, humedad y temperatura. Ya que con el pronóstico de la demanda de energía eléctrica, se podrá planear a mediano plazo el uso de reservas energéticas o empleo de vasos hidráulicos, con lo cual se tendrá la capacidad de monitorear la seguridad del suministro de energía eléctrica de la red y su operación financiera.

Todos los tipos y técnicas de pronósticos son por naturaleza extrapolativos, es decir, que incluyen interpolación, o bien predicen con datos existentes, lo cual se puede considerar como extrapolación. Y una de las técnicas para resolver el problema del pronóstico de la demanda de energía eléctrica a mediano plazo, son las redes neuronales artificiales, las cuales emulan a las redes neuronales biológicas (cerebro humano), esto permite resolver grandes problemas de optimización como el problema del pronóstico de la demanda de energía eléctrica, con lo cual se puede conocer la potencia que es demandada a un sistema eléctrico.

Si el pronóstico realizado se apega lo más posible a la realidad, se aportarán un sin número de parámetros útiles para la planificación, evitando amenazas en el exceso o baja capacidad de producción. En cambio, una sobrestimación en los pronósticos dará lugar a malas decisiones de planeación, provocándose con esto pérdidas de capital, por lo que en este trabajo, se busca reducir la incertidumbre por conocer la energía eléctrica que será demandada a mediano plazo en un sistema eléctrico de potencia para coadyuvar con el mejoramiento de la planeación y operación de un sistema eléctrico de potencia a mediano plazo.

## Abstract

This thesis presents a technique in artificial neuronal networks (ANN) in order to predict the medium-term load forecasting, comparing its results against the techniques of linear regression and autorregresivo methods. Therefore, this work aims at searching if ANN are able to minimize the uncertainty about knowing the demand of the future electrical load that will be had to medium term.

The task of forecasting the load of electrical energy is to know the most precise way of electrical power supply, using appropriate consumption factors. This involves having reliable information about approximated volumes of generation as well as population, humidity and temperature variables. Since the power reserve or hydraulic casings use would be planned to medium-term load forecast, this will have the capacity for monitoring the security of electrical supply system and its financial operation.

All types and techniques of load forecasting are extrapolation, that means, it includes interpolation, or predicts by using existing data, which can be considered as extrapolation. And artificial neuronal networks are one of the techniques to solve the problem of the medium-term load forecasting, which emulate the biological neuronal networks (human brain), this allows to solve big problems of optimization like the load forecasting problem which permits to know the power that is demanded by an electrical system.

If the forecast was made attached to the reality, a countless useful parameters will be provided for planning, avoiding threats of excess or low capacity of production. However, overestimating prognoses will give harmful planning decisions, causing itself capital losses that is why this work tries to reduce the uncertainty about knowing the electrical energy that will be demanded to medium term in an electrical power system to help improve planning and the operation of an electrical power system to medium term.



## CONTENIDO

CONTENIDO	PÁGINA
CARTA DE CESIÓN DE DERECHOS.....	<i>iii</i>
AGRADECIMIENTOS.....	<i>iv</i>
RESUMEN.....	<i>vii</i>
ABSTRACT .....	<i>viii</i>
ÍNDICE.....	<i>ix</i>
ÍNDICE DE FIGURAS.....	<i>xv</i>
ÍNDICE DE TABLAS.....	<i>xvii</i>
GLOSARIO DE TÉRMINOS.....	<i>xix</i>

## INDICE

### CAPÍTULO I    Introducción

1.1.    Introducción .....	2
1.2.    Objetivo de la tesis.....	3
1.3.    Justificación.....	3
1.4.    Alcance de la tesis.....	4
1.5.    Estado del arte.....	4
1.5.1. Extrapolación.....	4
1.5.2. Pronóstico estadístico.....	5
1.5.3. Pronóstico econométrico.....	5
1.5.4. Pronóstico por medio del uso final.....	5
1.5.5. Métodos más recientes.....	6
1.5.6. La importancia del pronóstico para la CFE.....	6
1.5.7. Un mal pronóstico.....	9
1.6.    Aportaciones de la tesis.....	9
1.7.    Estructura de la tesis.....	10

## **CAPÍTULO II Pronóstico de la demanda de energía eléctrica**

<b>2.1. Introducción al pronóstico</b>	<b>13</b>
<b>2.2. Horizonte de tiempo</b>	<b>14</b>
<b>2.2.1. El pronóstico a corto plazo</b>	<b>15</b>
<b>2.2.2. El pronóstico a mediano plazo</b>	<b>15</b>
<b>2.2.3. El pronóstico a largo plazo</b>	<b>16</b>
<b>2.3. Los factores que afectan la demanda eléctrica</b>	<b>17</b>
<b>2.3.1. Factores comunes</b>	<b>17</b>
<b>2.3.2. Factores ocasionales</b>	<b>17</b>
<b>2.3.3. Factores estacionales</b>	<b>18</b>
<b>2.4. Los datos históricos</b>	<b>18</b>
<b>2.5. La naturaleza de la demanda de energía eléctrica</b>	<b>19</b>
<b>2.6. Clasificación de métodos en el pronóstico</b>	<b>19</b>
<b>2.6.1. Clasificación general</b>	<b>20</b>
<b>2.6.2. Clasificación según la tendencia</b>	<b>20</b>
<b>2.7. Construcción de un modelo</b>	<b>21</b>
<b>2.7.1. Selección de variables</b>	<b>21</b>
<b>2.7.2. Procesamiento de los datos</b>	<b>21</b>
<b>2.8. Criterios para evaluar el desempeño de los modelos</b>	<b>22</b>
<b>2.8.1. Evaluación del modelo</b>	<b>22</b>
<b>2.8.2. Constancia paramétrica</b>	<b>22</b>
<b>2.8.3. Medidas de precisión</b>	<b>23</b>
<b>2.8.4. Comparación y combinación entre modelos de pronóstico</b>	<b>24</b>
<b>2.8.4.1 Comparación entre modelos</b>	<b>24</b>
<b>2.8.4.2 Combinación de modelos</b>	<b>24</b>
<b>2.8.5. Efectividad del método</b>	<b>24</b>
<b>2.9. Métodos de pronóstico utilizados en este trabajo</b>	<b>25</b>
<b>2.9.1. Regresión lineal</b>	<b>25</b>
<b>2.9.2. Métodos autorregresivos</b>	<b>27</b>
<b>2.9.3. Redes neuronales artificiales</b>	<b>30</b>

### **CAPÍTULO III Metodología de la red neuronal artificial por retropropagación.**

<b>3.1. Introducción</b>	<b>32</b>
<b>3.1.1. La neurona biológica</b>	<b>33</b>
<b>3.1.2. La neurona artificial</b>	<b>34</b>
<b>3.1.3. Un modelo de neurona artificial</b>	<b>34</b>
<b>3.2. Conceptos y definiciones</b>	<b>35</b>
<b>3.2.1. Paradigmas de aprendizaje</b>	<b>36</b>
<b>3.2.2. Modo de operación</b>	<b>36</b>
<b>3.2.3. Operaciones de las capas</b>	<b>37</b>
<b>3.3. El perceptrón</b>	<b>37</b>
<b>3.3.1. La red perceptrón</b>	<b>38</b>
<b>3.3.2. La red multicapa</b>	<b>38</b>
<b>3.3.3. Algoritmo de retropropagación del error</b>	<b>39</b>
<b>3.3.4. Coeficiente de aprendizaje</b>	<b>41</b>
<b>3.3.5. Elección de parámetros</b>	<b>42</b>
<b>3.3.6. Diagrama de flujo del modelo empleado</b>	<b>42</b>
<b>3.4. Aplicación de redes neuronales</b>	<b>42</b>
<b>3.4.1. Aplicaciones generales</b>	<b>42</b>
<b>3.4.2. Principales aplicaciones</b>	<b>43</b>
<b>3.4.2.1. Biológicas</b>	<b>44</b>
<b>3.4.2.2. Empresariales</b>	<b>44</b>
<b>3.4.2.3. Financieras</b>	<b>44</b>
<b>3.4.2.4. Medicina</b>	<b>44</b>
<b>3.4.2.5. Militares</b>	<b>45</b>
<b>3.4.2.6. Otros</b>	<b>45</b>
<b>3.4.3. Aplicaciones en ingeniería eléctrica</b>	<b>45</b>

**CAPÍTULO IV Pronóstico de la demanda de energía eléctrica utilizando una RNA por retropropagación**

<b>4.1. Introducción</b>	<b>48</b>
<b>4.1.1. Selección de variables</b>	<b>48</b>
<b>4.1.2. Preprocesamiento</b>	<b>48</b>
<b>4.1.3. Ajuste</b>	<b>49</b>
<b>4.1.4. Pronóstico</b>	<b>50</b>
<b>4.2. Definición del modelo RNA a utilizar</b>	<b>50</b>
<b>4.2.1. Justificación del tipo de red</b>	<b>51</b>
<b>4.2.2. Proceso de entrenamiento</b>	<b>51</b>
<b>4.2.3. Valores utilizados en el pronóstico</b>	<b>51</b>
<b>4.3. Simulaciones</b>	<b>52</b>
<b>4.3.1. Casos de simulación</b>	<b>53</b>
<b>4.3.2. Programas utilizados</b>	<b>53</b>
<b>4.4. Región norte</b>	<b>54</b>
<b>4.4.1. Ajuste de datos de la región norte</b>	<b>56</b>
<b>4.4.1.1. Ajuste de datos con regresión lineal</b>	<b>57</b>
<b>4.4.1.2. Ajuste de datos con VAR</b>	<b>58</b>
<b>4.4.1.3. Simulación con RNA</b>	<b>59</b>
<b>4.4.1.4. Resultados obtenidos durante el ajuste</b>	<b>61</b>
<b>4.4.2. Pronóstico de la demanda en la región norte</b>	<b>61</b>
<b>4.4.2.1. Pronóstico con Regresión Lineal</b>	<b>62</b>
<b>4.4.2.2. Pronóstico con VAR</b>	<b>63</b>
<b>4.4.2.3. Pronóstico con RNA</b>	<b>64</b>
<b>4.4.2.4. Resultados obtenidos</b>	<b>65</b>
<b>4.4.3. Comparación de resultados</b>	<b>65</b>
<b>4.5. Región sur</b>	<b>66</b>
<b>4.5.1. Ajuste de datos de la región sur</b>	<b>68</b>
<b>4.5.1.1. Ajuste de datos con regresión lineal</b>	<b>69</b>
<b>4.5.1.2. Ajuste de datos con VAR</b>	<b>70</b>
<b>4.5.1.3. Ajuste de datos con RNA</b>	<b>71</b>

4.5.1.4.Resultados obtenidos durante el ajuste.....	72
4.5.2. Pronóstico de la demanda en la región sur.....	73
4.5.2.1.Pronóstico con regresión lineal.....	73
4.5.2.2.Pronóstico con VAR.....	74
4.5.2.3.Pronóstico con RNA.....	75
4.5.2.4.Resultados obtenidos.....	76
4.5.3. Comparación de resultados.....	76
4.6. Región Istmo.....	78
4.6.1. Ajuste de datos de la región Istmo.....	80
4.6.1.1.Ajuste de datos con regresión lineal.....	80
4.6.1.2.Ajuste de datos con VAR.....	82
4.6.1.3.Ajuste de datos con RNA.....	83
4.6.1.4.Resultados obtenidos.....	84
4.6.2. Pronóstico de la demanda en la región del Istmo.....	84
4.6.2.1.Pronóstico con Regresión Lineal.....	85
4.6.2.2.Pronóstico con VAR.....	86
4.6.2.3.Pronóstico con RNA.....	87
4.6.2.4.Resultados obtenidos.....	88
4.6.3. Comparación de resultados.....	88
4.7. Región arábiga de Dhaharán.....	89
4.7.1. Ajuste de datos de la región arábiga.....	92
4.7.1.1.Ajuste de datos con regresión lineal.....	92
4.7.1.2.Ajuste de datos con VAR.....	93
4.7.1.3.Ajuste de datos con RNA.....	94
4.7.1.4.Resultados obtenidos durante el ajuste.....	96
4.7.2. Pronóstico de la demanda en la región arábiga.....	96
4.7.2.1.Pronóstico con Regresión Lineal.....	96
4.7.2.2.Pronóstico con VAR.....	97
4.7.2.3.Pronóstico con RNA.....	98
4.7.2.4.Resultados obtenidos.....	99
4.7.3. Comparación de resultados.....	99

<b>4.8. Análisis del estudio</b> .....	<b>101</b>
<b>4.8.1. Regresión lineal</b> .....	<b>102</b>
<b>4.8.2. Método autorregresivo</b> .....	<b>103</b>
<b>4.8.3. Redes neuronales artificiales</b> .....	<b>104</b>

**CAPÍTULO V Conclusiones y recomendaciones**

<b>5.1. Resumen de aspectos generales</b> .....	<b>107</b>
<b>5.2. Conclusiones del estudio del pronóstico de la demanda</b> .....	<b>108</b>
<b>5.2.1. Regresión lineal</b> .....	<b>108</b>
<b>5.2.2. Método autorregresivo</b> .....	<b>109</b>
<b>5.2.3. Redes neuronales artificiales</b> .....	<b>110</b>
<b>5.3. Recomendaciones para trabajos futuros</b> .....	<b>112</b>

<b>REFERENCIAS</b> .....	<b>115</b>
--------------------------	------------

**ANEXOS**

<b>"A" Datos región norte en su estado normal</b> .....	<b>118</b>
<b>"B" Datos región norte estandarizados</b> .....	<b>119</b>
<b>"C" Valores región sur en su estado natural</b> .....	<b>120</b>
<b>"D" Datos región sur estandarizados</b> .....	<b>121</b>
<b>"E" Datos región Istmo en su estado natural</b> .....	<b>122</b>
<b>"F" Datos región Istmo estandarizados</b> .....	<b>123</b>
<b>"G" Datos naturales de la región arábiga</b> .....	<b>124</b>
<b>"H" Datos estandarizados de la región arábiga</b> .....	<b>125</b>
<b>"I" Análisis de datos de la región norte</b> .....	<b>126</b>
<b>"J" Análisis de datos de la región sur</b> .....	<b>127</b>
<b>"K" Análisis de datos del Istmo</b> .....	<b>127</b>
<b>"L" Análisis de datos de la región arábiga</b> .....	<b>128</b>

## APÉNDICES

"A" Programa 1 R.L.....	130
"B" Programa 2 VAR.....	134
"C" Programa 3 RNA.....	137
"D" Manual de operación del programa de regresión lineal.....	145
"E" Manual de operación del programa de VAR.....	147
"F" Manual de operación del programa de RNA.....	149
"G" Introducción a las series de tiempo.....	152

## ÍNDICE DE FIGURAS Y GRÁFICAS

<b>FIGURA</b>	<b>PAGINA</b>
2.1. Usos del pronóstico.....	13
2.2. Flujo de información del pronóstico.....	14
2.3. Gráfica de la demanda en relación a las estaciones climatológicas.....	18
2.4. Curva de la demanda de energía eléctrica zona norte.....	19
2.5. Esquema generalizado de un pronóstico.....	21
2.6. Diagrama de flujo del programa de RL.....	26
2.7. Diagrama de flujo del programa del método autorregresivo.....	29
3.1. El cerebro humano y la RNA.....	32
3.2. Neurona biológica.....	33
3.3. Neurona artificial.....	34
3.4. La red perceptrón.....	37
3.5. Representación del flujo de la información de la RNA por retropropagación.....	40
3.6. Diagrama de flujo del programa de la RNA por retropropagación.....	41
4.1. Esquema de la RNA empleada.....	50
4.2. Esquema de la RNA en cascada.....	52
4.3. Gráfica de la demanda media mensual para la región norte.....	54
4.4. Gráfica de la temperatura media mensual para la región norte.....	54
4.5. Gráfica de la humedad media mensual para la región norte.....	55
4.6. Gráfica del crecimiento medio de la población para la región norte.....	55
4.7. Gráfica de los datos estandarizados para la región norte.....	56
4.8. Gráfica del ajuste y el pronóstico con regresión lineal para la región norte.....	57

4.9. Gráfica del ajuste y el pronóstico con VAR para la región norte.....	59
4.10. Gráfica del ajuste con RNA para la región norte.....	60
4.11. Gráfica del pronóstico con regresión lineal para la región norte.....	62
4.12. Gráfica del pronóstico con VAR para la región norte.....	63
4.13. Gráfica del pronóstico con RNA para la región norte.....	64
4.14. Gráfica comparativa del ajuste del método de R.L. contra RNA.....	65
4.15. Gráfica comparativa del pronóstico del método de R.L. contra RNA.....	66
4.16. Gráfica de la demanda media mensual para la región sur.....	66
4.17. Gráfica de la temperatura media mensual para la región sur.....	67
4.18. Gráfica de la humedad media mensual para la región sur.....	67
4.19. Gráfica del crecimiento de la población para la región sur.....	67
4.20. Gráfica de los datos estandarizados para la región sur.....	68
4.21. Gráfica del ajuste con regresión lineal para la región sur.....	69
4.22. Gráfica del ajuste alcanzado con VAR para la región sur.....	71
4.23. Gráfica del ajuste mediante RNA utilizando la temperatura para la región sur.....	71
4.24. Gráfica de pronósticos con regresión lineal para la región sur.....	73
4.25. Gráfica del pronóstico con VAR para la región sur.....	74
4.26. Gráfica del pronóstico alcanzado con RNA para la región sur.....	75
4.27. Gráfica comparativa del ajuste del método de VAR contra RNA.....	77
4.28. Gráfica comparativa del pronóstico del método de VAR contra RNA.....	77
4.29. Gráfica de la demanda media mensual de la región Istmo.....	78
4.30. Gráfica de la temperatura media de la región Istmo.....	78
4.31. Gráfica de la humedad media de la región Istmo.....	79
4.32. Gráfica del crecimiento poblacional de la región Istmo.....	79
4.33. Gráfica de los datos estandarizados de la región Istmo.....	80
4.34. Gráfica del ajuste con regresión lineal para el Istmo.....	81
4.35. Gráfica del ajuste obtenido con VAR Para el Istmo.....	82
4.36. Gráfica del ajuste utilizando RNA con la temperatura, para el Istmo.....	83
4.37. Gráfica del pronóstico con regresión lineal para el Istmo.....	85
4.38. Gráfica del pronóstico con VAR para la región Istmo.....	86
4.39. Gráfica del pronóstico con RNA para la región Istmo.....	87



4.40. Gráfica comparativa del ajuste del método de R.L. contra RNA.....	88
4.41. Gráfica comparativa del pronóstico del método de R.L. contra RNA.....	89
4.42. Gráfica de la demanda media mensual para la región arábiga.....	89
4.43. Gráfica de la temperatura media mensual para la región arábiga.....	90
4.44. Gráfica de la humedad media mensual para la región arábiga.....	90
4.45. Gráfica del crecimiento mensual de la población para la región arábiga.....	90
4.46. Gráfica de la radiación solar media mensual para la región arábiga.....	91
4.47. Gráfica de los datos estandarizados para la región arábiga.....	91
4.48. Gráfica del ajuste con regresión lineal para la región arábiga.....	93
4.49. Gráfica del ajuste y el pronóstico con VAR Para la región arábiga.....	93
4.50. Gráfica del ajuste y el pronóstico utilizando la humedad para la región arábiga.....	95
4.51. Gráfica del pronóstico con regresión lineal para la región arábiga.....	96
4.52. Gráfica del pronóstico con VAR para la región arábiga.....	97
4.53. Gráfica del pronóstico con RNA para la región arábiga.....	98
4.54. Gráfica comparativa del ajuste del método de R.L. contra RNA.....	100
4.55. Gráfica comparativa del pronóstico alcanzado entre el método de R.L. y RNA.....	100
AG.1. Representación del filtrado de una serie.....	153
AG.2. Representación de dos filtros en serie.....	154

### ÍNDICE DE TABLAS

T A B L A	P A G I N A
4.1. Niveles de correlación para la región norte.....	56
4.2. Ajuste de la curva mediante el método de regresión lineal.....	58
4.3. Valores obtenidos mediante el método de VAR.....	59
4.4. Valores obtenidos mediante el método de RNA.....	60
4.5. Evaluación de resultados para la región norte.....	61
4.6. Pronóstico de la demanda mediante el método de regresión lineal.....	62
4.7. Valores obtenidos mediante el método de VAR.....	63
4.8. Valores obtenidos mediante el método de RNA.....	64
4.9. Resultados obtenidos para la región norte.....	65
4.10. Niveles de correlación para la región sur.....	68

4.11.	Valores del ajuste alcanzado mediante el método de regresión lineal	69
4.12.	Valores del ajuste alcanzado mediante VAR	70
4.13.	Valores del ajuste alcanzado mediante RNA	72
4.14.	Resultados obtenidos para la región sur durante el ajuste	72
4.15.	Pronóstico de la demanda alcanzado mediante el método de regresión lineal	74
4.16.	Valores obtenidos mediante el método de VAR	75
4.17.	Valores obtenidos mediante el método de RNA	76
4.18.	Evaluación de los pronósticos alcanzados por los distintos métodos	76
4.19.	Niveles de correlación para la región Istmo	80
4.20.	Valores obtenidos mediante regresión lineal	81
4.21.	Valores obtenidos mediante regresión lineal	82
4.22.	Valores obtenidos mediante regresión lineal	83
4.23.	Resultados obtenidos durante el ajuste, para la región del Istmo	84
4.24.	Pronóstico de la demanda alcanzado mediante el método de regresión lineal	85
4.25.	Valores obtenidos mediante el método de VAR	86
4.26.	Valores del pronóstico obtenido mediante el método de RNA	87
4.27.	Evaluación de los pronósticos alcanzados para el Istmo	88
4.28.	Niveles de correlación para la región arábiga	91
4.29.	Valores obtenidos durante el ajuste mediante regresión lineal	92
4.30.	Valores obtenidos durante el ajuste mediante VAR	94
4.31.	Valores obtenidos durante el ajuste mediante VAR	95
4.32.	Resultados obtenidos para la región arábiga	96
4.33.	Pronóstico de la demanda mediante el método de Regresión lineal	97
4.34.	Pronóstico de la demanda mediante el método de VAR	98
4.35.	Pronóstico de la demanda mediante el método de RNA	99
4.36.	Resultados obtenidos para la región arábiga	99
4.37.-	Resultados obtenidos para cada región, con su topología	105
5.1.	Resultados obtenidos, por medio de regresión lineal	109
5.2.	Resultados obtenidos, por medio de VAR	110
5.3.	Resultados obtenidos, por medio de RNA	111

## GLOSARIO DE TÉRMINOS

SEP	Sistema Eléctrico de Potencia
SENER	Secretaría de Energía
SEN	Sistema Eléctrico Nacional
CFE	Comisión Federal de Electricidad
LSPEE	Ley del Servicio Público de Energía Eléctrica
RLSPEE	Reglamento de la Ley del Servicio Público de Energía Eléctrica
POISE	Programa de Obras de Inversiones del Sector Eléctrico
RNAs	Redes neuronales artificiales
RNA	Rede neuronal artificial
VAR	Vector autorregresivo
R.L.	Regresión lineal
ESs	Sistemas expertos
PIB	Producto interno bruto
$\tau$	Número de pronósticos
$h$	Horizonte de pronóstico
$e_{(T+i)}$	Error de predicción
$y_{T+h}$	Valor real
$\hat{y}_{T+h}$	Valor observado
$Y_t$	Demanda pronosticada para el periodo $t$ .
$X_{ti}$	La $i$ -ésima variable independiente (temperatura, humedad, población)
$\varepsilon_t$	Error aleatorio
$B_0, B_1, \dots, B_p$	Parámetros desconocidos
$a$	Estimación encontrada

$\sigma_x$	Desviación estándar de $x$
$\rho(X, Y)$	Coefficiente de correlación
$\Sigma$	Sumador
$\theta_k$	Umbral
$f()$	Función de activación
$f'_i()$	La derivada de la función de activación
$x_j$	Una señal de entrada
$w_{kj}$	Peso o fuerza de la conexión con la entrada $j$ -ésima
$\mu_k$	Resultado de la suma ponderada
$y_k$	Salida observada de la RNA
$E(t)$	Error cuadrático
$\delta_i(t)$	Señal de error
$\alpha$	Coefficiente de aprendizaje
$\Delta w_{ij}(t)$	Incremento del peso $ij$
$m.$	Momento
$\gamma$	Constante de regularización
RC	Resistencia capacitor
BPTT	Retropropagación a través del tiempo
°C	Grados centígrados
MWh	Mega Watt hora
P.U.	Valores en por unidad

# CAPÍTULO I

## INTRODUCCIÓN

## 1.1. Introducción

El pronóstico sano y realista es la llave de un buen planeamiento en cualquier industria. Tal como en la industria eléctrica; es decir, que buenos pronósticos de la demanda de energía eléctrica son útiles para planear los recursos con los que el sistema pueda resolver su demanda futura. Por lo tanto, la importancia del pronóstico es evidente. *“Al mismo tiempo, la imposibilidad de desarrollar pronósticos verdaderamente exactos debe ser admitida”*. El hecho simple de que no podemos prever el futuro debe ser reconocido.[1][2][3]

Por lo tanto, para todo planificador de un sistema eléctrico de potencia debe ser una preocupación continua utilizar el pronóstico para mejorar la eficiencia en el suministro de energía eléctrica, con el que se puede asistir para brindar el óptimo suministro de energía con la más alta calidad de servicio, de tal forma que el suministro debe ser confiable, asegurando lo siguiente: [4][5]

- Entregar el suministro de energía en forma confiable a todos los puntos.
- Los límites de frecuencia y de tensión deben estar dentro de valores aceptables.
- El sistema debe operar en medida de lo posible, con costos mínimos y con el mínimo de alteraciones ambientales y ecológicas.

Dentro de las técnicas para dar solución al pronóstico de la demanda de energía eléctrica, se encuentran las redes neuronales artificiales, con las cuales se busca el punto óptimo en la operación del sistema eléctrico a mediano plazo, utilizando las restricciones propias del funcionamiento del sistema. [7][8][9]

El objetivo principal de cualquier compañía de electricidad regulada, es proporcionar fuentes adecuadas y confiables de electricidad a los consumidores, con un precio razonable. Este objetivo requiere pronósticos de la demanda, sin embargo, esto no es fácil ya que las necesidades humanas provocan patrones de consumo de energía que describen diferentes formas. Por ejemplo, en una casa del norte de la república, se necesita de un acondicionador de aire, que consumirá cierta cantidad de electricidad en cierto tiempo; este uso de energía se emplea en el deseo de un individuo para refrescarse. Y así como este ejemplo, la curva característica de la demanda se basa en un sin número de variables de todo tipo. Así pues, la gran variedad de consumidores y diferentes tipos de usos finales de energía eléctrica crean una gran variedad de

demandas distintas entre si. Con toda esta clase de consumidores, y la gran cantidad de variables que en cierto momento influyen directa o indirectamente en la demanda de energía eléctrica, se busca realizar el pronóstico de la demanda con un mínimo de error aceptable. [10]

## **1.2. Objetivo de la tesis**

Pronosticar la demanda de energía eléctrica a mediano plazo, empleando una red neuronal artificial por retropropagación del error, para conocer la energía eléctrica que debe ser suministrada de acuerdo al crecimiento y operación del sistema. Utilizando las variables de: crecimiento medio mensual de la población, comportamiento de la temperatura, humedad y radiación, para proporcionar eficientemente el pronóstico con un mínimo de error aceptable.

## **1.3. Justificación**

Para todas las organizaciones es importante realizar pronósticos de ciertas variables, las compañías que operan sistemas eléctricos de potencia no son la excepción, ya que requieren minimizar la incertidumbre de la demanda que se tendrá a mediano plazo o a otro horizonte de tiempo, según se desee (corto, mediano o largo plazo), tomando como ventaja la información disponible para planear la operación del sistema, según lo pronosticado.

La tarea de planificar la demanda de energía eléctrica consiste en pronosticar en forma segura el suministro de energía eléctrica, o más exactamente, los factores de consumo. Esto involucra tener información confiable de los volúmenes aproximados de generación, así como de los factores de tiempo, población, humedad.

Una de las herramientas para predecir la demanda de energía eléctrica, son las redes neuronales artificiales que procesan información emulando las redes neuronales biológicas (cerebro humano), estos sistemas están basados en un elevado número de elementos básicos (neuronas artificiales), que se encuentran interconectadas entre si, entrenadas con patrones establecidos, para dar una respuesta apegada al patrón de entrenamiento, al emplear las características de las redes neuronales artificiales en el pronóstico de la demanda de energía eléctrica a mediano plazo, se optimizará el suministro de energía eléctrica, ya que permitirá conocer de antemano la

potencia que es demandada al sistema eléctrico. Tomando la información disponible para proporcionar eficientemente el pronóstico requerido.

Además; al pronosticar la demanda de energía eléctrica, se podrá planear a mediano plazo el consumo de reservas energéticas y empleo de vasos hidráulicos, con lo cual se tendría la capacidad de monitorear la seguridad del suministro de energía eléctrica de la red y su operación financiera.

#### **1.4. Alcance de la tesis**

Proporcionar el pronóstico de la demanda de energía eléctrica a mediano plazo, empleando una red neuronal artificial por retropropagación del error, utilizando las variables de: crecimiento medio mensual de la población, del comportamiento de la temperatura, humedad y radiación, buscando que el pronóstico encontrado sea mejor que el dado por otros métodos aplicados con anterioridad a este problema.

#### **1.5. Estado del arte**

Los primeros enfoques trataron de pronosticar la demanda, sin evaluar la credibilidad de la información obtenida [11], otros más supusieron que los factores que modificaban la demanda, eran principalmente las condiciones atmosféricas o la demanda histórica; en cambio otras teorías consideraron que la carga está en función del tiempo ( $t$ ). Más recientemente, se combinaron estos conceptos para proponer el modelo en el cual el pronóstico depende de todas las variables susceptibles de variar la demanda en un SEP tales como: condiciones atmosféricas, demanda histórica, situación y crecimiento económico.

A continuación se dará una breve descripción de algunas técnicas de pronóstico:

##### **1.5.1. Pronóstico por extrapolación**

La extrapolación emplea la observación de una serie de tiempo, tal como el consumo de energía eléctrica. La extrapolación se basa en la tendencia del crecimiento, entonces los datos pronosticados a futuro, serán una continuación de un patrón perceptible de la tendencia. Este método específico emplea para su análisis los índices de crecimiento, y el uso de las gráficas de



los datos históricos. Esta técnica produce resultados aceptables. Sin embargo, los factores que afectan el crecimiento no son identificados plenamente, ni tampoco su efecto sobre el pronóstico. [12]

### **1.5.2. Pronóstico Estadístico**

El pronóstico estadístico se basa en la identificación de correlaciones entre la demanda eléctrica y las variables que afectan la propia demanda. Los métodos de correlación incluyen diagramas de dispersión, correlación simple y múltiple. Los resultados de estas técnicas, especialmente los métodos más sofisticados, no se pueden obtener fácilmente, sino que deben ser evaluadas técnicamente con base en su propio método, estos resultados, pueden proporcionar índices de las causas del crecimiento y variación en la demanda. Esto conduce a una comprensión más clara de los factores que afectan el crecimiento de la demanda de energía eléctrica y la importancia relativa de otras variables que afectan la demanda.[12]

### **1.5.3. Pronóstico Econométrico**

La teoría económica comienza estimando relaciones causales entre el consumo de energía (la variable dependiente) y los factores que influyen en su consumo (las variables independientes). Las relaciones son estimadas aplicando el método de mínimos cuadrados ordinario u otros métodos más sofisticados de series de tiempo, empleando datos históricos. Una vez que la relación se haya establecido, se insertan valores futuros de las variables independientes y se proyectan a la variable dependiente, dando como resultado el pronóstico del consumo de la demanda de energía eléctrica. Lo que permite la evaluación explícita de los impactos de cada variable que afecta el cambio en el consumo de la energía eléctrica.[13]

### **1.5.4. Pronóstico por medio del uso final**

El uso final se centra en las aplicaciones finales de la electricidad en el sector residencial, comercial e industrial. Por ejemplo, en el sector residencial, la calefacción, el aire acondicionado, la refrigeración y el equipo electrodoméstico. Con este método se especifica el consumo de la energía correspondiente, entonces la estructura básica del modelo de pronóstico de uso final, se centra alrededor del uso que se da a la energía eléctrica. [11]

### **1.5.5. Métodos más recientes**

Algunos de los métodos más recientes usados en desarrollar modelos de pronóstico de la demanda de energía eléctrica, son las redes neuronales artificiales (RNAs) y sistemas expertos (ESs). Los modelos de sistemas expertos pueden incorporar los juicios de expertos y reglas en el pronóstico de la demanda, mientras que la exactitud de los modelos de RNAs, residen en su capacidad de combinar el efecto de series de tiempo de los patrones de la demanda, con el efecto de las variables seleccionadas. Los modelos de pronóstico de sistemas expertos y de RNA están basados actualmente en el desarrollo y los resultados que se están divulgando en la literatura donde se comparan con los modelos estadísticos comunes. [3][14]

Dentro de los métodos más recientes, se encuentran los métodos heurísticos, los cuales se pueden considerar para dar solución del problema del pronóstico, sin duda por la necesidad de buscar nuevas herramientas que permitan ofrecer soluciones rápidas a problemas reales. Es importante destacar el hecho de que los algoritmos heurísticos por sí solos no garantizan una solución óptima, aunque su propósito es encontrar una solución cercana al óptimo en un tiempo razonable, algunos de estos métodos, son los siguientes: Búsqueda Tabú (basado en la memoria), Templado Simulado (basado en leyes de termodinámica), Algoritmos Genéticos (basado en evolución), Búsqueda de la colonia (basado en colonias de hormigas).[15][16][17]

### **1.5.6. La importancia del pronóstico para la CFE**

El estudio Desarrollo del Mercado Eléctrico para la Comisión Federal de Electricidad, se elabora anualmente y tiene por objeto determinar el pronóstico de la demanda de energía eléctrica, a nivel regional y de zonas. Los resultados de este estudio permiten establecer la localización y la capacidad necesaria, tanto de generación como de transmisión y transformación, para satisfacer dicha demanda.

Este proyecto se orienta a analizar las tendencias del consumo nacional de electricidad por sector Consumidor (residencial, comercial, servicios, agrícola, empresa mediana y gran industria), considerando tanto el suministro que proporcionan las empresas del sector público como el autoabastecimiento de algunos grandes usuarios industriales. A partir de este análisis, se construyen modelos econométricos que establecen la relación entre el consumo y las ventas

anuales de electricidad, como variables a explicar, y algunas variables económicas, demográficas y tecnológicas independientes, como determinantes del comportamiento del nivel de consumo y ventas de electricidad en cada uno de esos sectores de usuarios.

### **Documento de Prospectiva del Sector Eléctrico. [19]**

Según lo dispuesto en el Artículo 67 del Reglamento de la Ley del Servicio Público de Energía Eléctrica (RLSPEE), la CFE debe presentar anualmente a la Secretaría de Energía (SENER), los primeros cuatro capítulos del Documento de Prospectiva del Sector Eléctrico. Éste describe la evolución esperada de la demanda, las características del sistema existente, la capacidad de generación y transmisión previstas; además, compara distintas opciones para satisfacer la demanda futura en los próximos 10 años.

La información contenida en el documento de prospectiva, incluye un programa de expansión de referencia para dar a conocer la magnitud y ubicación regional de la capacidad adicional de generación que requiere el SEN. Ésta podrá cubrirse, en gran medida, mediante proyectos de generación desarrollados por el sector privado, de acuerdo con el procedimiento previsto en la Ley del Servicio Público de Energía Eléctrica (LSPEE) y en su reglamento.

Durante el período que se informa, la metodología de pronóstico continuó mejorando, con base en un sustento más sólido de la factibilidad de realización de proyectos de autoabastecimiento y cogeneración; y con ello, los resultados del análisis de la demanda autoabastecida y su proyección correspondiente, que para este tipo de proyectos, toma como base los permisos solicitados a la Comisión Reguladora de Energía (CRE). Se pretende que esta mejora y refinamiento de la metodología dé mayor certidumbre a los pronósticos de demanda que sirven de base para la programación de las obras requeridas para el SEN.

### **Programa de Obras e Inversiones del Sector Eléctrico (POISE). Actualización y evaluación del programa de obras de generación**

De acuerdo con lo dispuesto en el Artículo 66, Fracción II, del RLSPEE, la CFE debe presentar anualmente a la SENER los programas destinados a realizar las obras que el suministrador pretende ejecutar para la prestación del servicio público, a fin de satisfacer la demanda futura en los próximos diez años.

A la actualización de este programa en el año, se incorporarán las mejoras metodológicas descritas previamente en el proyecto “Documento de Prospectiva del Sector Eléctrico”. En este sentido, la entrada de las unidades generadoras debe ser programada, tomando en cuenta las capacidades y fechas de inicio de operación de los proyectos de autoabastecimiento y cogeneración. En esta última modalidad, destaca el potencial de Petróleos Mexicanos (PEMEX), cuyos proyectos tienen un importante grado de avance en las etapas de definición, licitación y construcción, por lo que se estima, entre en operación una cantidad significativa de MW durante los próximos diez años.

### **Programa de Obras de Inversiones del Sector Eléctrico (POISE). Actualización y evaluación del programa de obras de transmisión**

Considera el programa vigente de centrales generadoras, que incluye los proyectos de producción externa y los de autoabastecimiento y cogeneración, determina los refuerzos de transmisión óptimos, necesarios en el SEN. Esto, dentro del marco de un programa de mínimo costo a largo plazo, para el período de interés, conforme a los criterios técnicos y económicos acordados en la CFE.

### **Programa de producción y combustibles**

Este programa constituye el resultado de estudios de operación del sistema eléctrico, basados en las versiones actualizadas del programa de obras, el estudio del mercado eléctrico y el pronóstico de precios nacionales e internacionales de los combustibles; asimismo, de las políticas y los criterios de operación establecidos para garantizar la confiabilidad del suministro a costo mínimo, tanto en energía como en capacidad de generación.

La participación de la CFE con sus aportaciones en el Grupo de Combustibles, contribuye a que PEMEX tome las acciones que garanticen el suministro de combustibles y en los años futuros le permitan a la CFE un ahorro ante los compromisos establecidos con los productores externos de energía.

### **1.5.7. Un mal pronóstico**

Este punto tiene como fin plantear el supuesto de lo que conllevaría un mal estudio de pronóstico, sea éste manipulado o accidental, si se presentan las necesidades de una nueva capacidad de generación determinadas por el Gobierno Federal, las cuales están sobredimensionadas y son manipuladas para justificar una reforma eléctrica. [18]

Los requerimientos de capacidad que contemplan los documentos de prospectiva del sector eléctrico que publica la Secretaría de Energía, se determinan con base en el pronóstico de la demanda de energía eléctrica, los proyectos en proceso y los programas de retiro de capacidad.

Ahora bien, para juzgar la validez de la metodología utilizada, sólo debe tomarse en cuenta la exactitud de sus pronósticos, cualquier otro aspecto es irrelevante. Si una metodología genera de manera consistente pronósticos cercanos a la realidad, puede considerarse confiable.

Así por ejemplo, y según la referencia [18], en 1995 se proyectó una demanda de 140,218 GWh para el año 2000, siendo el consumo real de 155,349 GWh en ese año. Esto significó un pronóstico de un 10.8% menor a la realidad, lo cual llevaría a una inversión menor, dando como resultado para el sistema eléctrico nacional, prepararse para contar con una carga instalada menor a la carga demandada; lo cual significaría que la eficiencia en el suministro de energía eléctrica, no sería suficiente para proporcionar el óptimo suministro de energía con la calidad de servicio deseado por el usuario, de tal forma que el suministro no sería confiable, además de que el sistema no operaría con costos mínimos ni con el mínimo de alteraciones ambientales y ecológicas.

### **1.6. Aportaciones de esta tesis**

- Esta tesis representa la disponibilidad de una metodología y herramienta computacional, para dar solución al problema del pronóstico de la demanda de energía eléctrica a mediano plazo, utilizando redes neuronales artificiales por retropropagación del error. Con lo que se aportarían criterios para la toma de decisiones en una adecuada planeación y operación de un sistema eléctrico de potencia.

- Con el desarrollo de éste trabajo se puede constatar la utilidad que tiene el método de redes neuronales artificiales por retropropagación del error para resolver el problema del pronóstico de la demanda de energía eléctrica, empleando variables tales como temperatura, humedad, radiación solar, crecimiento poblacional y la demanda de energía eléctrica de distintas regiones analizadas.
- Este trabajo permite comparar el grado de incertidumbre que presentan los métodos de; regresión lineal, vector autorregresivo y redes neuronales artificiales. Que con el último de los nombrados se obtienen los mejores ajustes y pronósticos, dando como resultado que con las RNA se pueden alcanzar pronósticos más aproximados a la realidad.

### **1.7. Estructura de la tesis**

El trabajo desarrollado en esta tesis, se encuentra organizado en 5 capítulos y diversos anexos. A continuación se presenta una breve descripción del contenido de cada capítulo:

*Capítulo I.-* Introducción. En el presente capítulo se presenta una breve introducción a la descripción del problema del pronóstico, así como el alcance y objetivo que la tesis espera alcanzar, para lo cual se presenta el estado del arte del pronóstico, con el fin de establecer las condiciones actuales de dicho problema.

*Capítulo II.-* Pronóstico de demanda de energía eléctrica y métodos de pronóstico. En este capítulo, se detallan en forma breve los métodos de pronósticos más comúnmente aplicados al pronóstico de la demanda de energía eléctrica, los factores que afectan directa o indirectamente el comportamiento de la demanda de energía eléctrica, los diferentes horizontes de tiempo para los cuales se realiza el pronóstico de la demanda, según el objetivo del pronóstico deseado. Así mismo, se realiza una descripción general de los criterios para evaluar el desempeño de los métodos de pronóstico.

**Capítulo III.-** Metodología de la red neuronal artificial por retropropagación. Para dar continuidad al capítulo anterior aquí se describen de manera general los conceptos básicos y definiciones del modelo de la RNA empleada, así como sus principales modos de operación y paradigmas de aprendizaje de la red de retropropagación de error, esto con el fin de facilitar su estudio, enfocado principalmente a solucionar el problema del pronóstico de la demanda de energía eléctrica.

**Capítulo IV.-** Pronóstico de la demanda de energía eléctrica utilizando redes neuronales artificiales. Este capítulo representa el punto central del trabajo, ya que en su contenido se efectúan 4 simulaciones del problema de pronóstico con diferente grado de complejidad, con el pronóstico obtenido, se llevan a cabo comparaciones de los resultados con los métodos de regresión lineal, vector autorregresivo; estableciendo cual de ellos es el que se aproxima más a la demanda real, a fin de corroborar el objetivo de la tesis. Los pronósticos obtenidos son analizados para establecer el método más preciso, para la solución del pronóstico de la demanda de energía eléctrica a mediano plazo.

**Capítulo V.-** Conclusiones y recomendaciones. Por último en este Capítulo, se presentan las conclusiones a que llevaron los trabajos realizados, y al ser favorables los resultados para obtener el pronóstico mediante RNA, se propone este método para trabajos futuros; esto a partir de que resulto el método más exacto para la obtención del pronóstico.

**Apéndices y anexos.-** Al final de este trabajo se presenta la información utilizada en las diferentes simulaciones, así como el código fuente, manuales de empleo de los programas de cómputo utilizados para la obtención del pronóstico y una breve introducción a las series de tiempo.

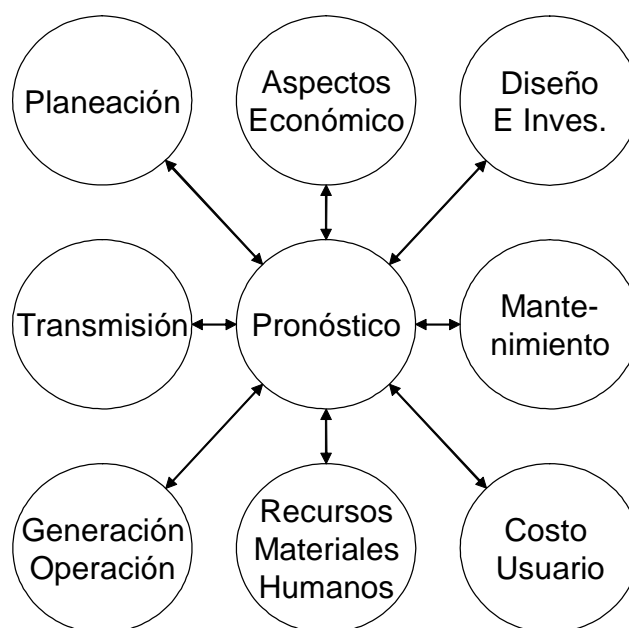
# CAPÍTULO II

## **PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA**



## 2.1 Introducción al pronóstico

El pronóstico de la demanda de energía eléctrica para un sistema eléctrico de potencia, ha causado interés desde el momento en que las redes eléctricas se instalaron como sistema básico de transporte y distribución de energía, y tras haber proliferado el uso masivo de la energía eléctrica en el entorno industrial, comercial y doméstico. Por lo anterior, el pronóstico es útil para diferentes usos, como se puede ver en la figura 2.1 [11].



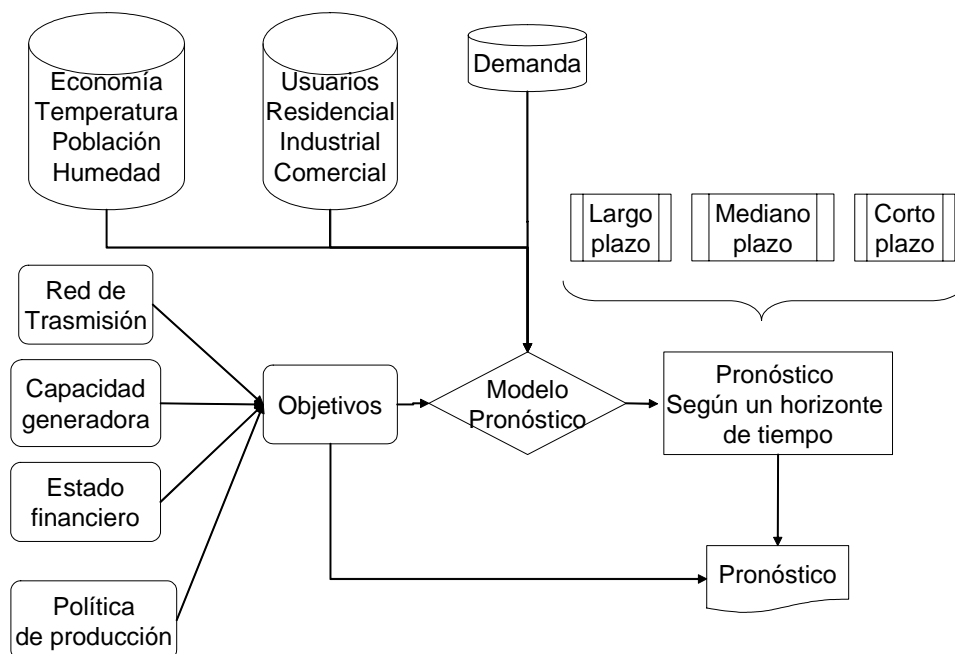
*Figura 2.1 Usos del pronóstico*

El pronóstico para la compañía de electricidad se ha desarrollado a grandes pasos sobre las últimas décadas. Las extrapolaciones de las tendencias históricas del consumo de energía, habían servido bastante bien durante el tiempo en que los precios de producción y las tasas de crecimiento fueron constantes, pero cuando ya no se presentaron estas características en la demanda, la extrapolación resultó inadecuada, cuando aparece el análisis de los costos de producción de la energía a finales de los 60s y principios de los 70s. Estas técnicas no podían hacer frente a variaciones en tarifas de crecimiento entre los diversos sectores consumidores de energía eléctrica [5][6][11].

Si los pronósticos realizados se apegan lo más posible a la realidad, se aportarán en consecuencia, un sin número de parámetros útiles para la planificación, evitando amenazas en el exceso o baja capacidad de producción. En cambio, una sobrestimación en los pronósticos, dan lugar a malas decisiones, provocándose con esto, pérdidas de capital.

## 2.2 Horizonte de tiempo

El pronóstico de la demanda de energía eléctrica, se clasifica principalmente en tres horizontes de tiempo: El pronóstico a corto plazo, este es útil en la determinación de la operación de las unidades y del despacho económico. El pronóstico a mediano plazo, es requerido para la planeación del uso de energéticos y programar el mantenimiento. El pronóstico a largo plazo, es necesario para la planeación de la expansión del sistema eléctrico, el análisis financiero, y como se mencionó anteriormente, el pronóstico de la demanda se puede obtener según su clasificación, ver figura 2.2 [4][5][6]:



*Figura 2.2. Flujo de información del pronóstico*

El pronóstico de la demanda de energía eléctrica es a cierto grado incierto sin importar que los límites de confianza se fijen cuidadosamente, el pronóstico se basa fundamentalmente en la probabilidad. El trabajo del pronosticador es entonces proporcionar un pronóstico lo más fiable posible. El encargado de elaborar el pronóstico tiene que identificar el tipo de problema a resolver, tiene que recopilar los datos que requiera, construir un modelo matemático y finalmente generar y validar dicho pronóstico. Para este caso en particular, se proporciona un método de pronóstico para obtener la demanda de energía eléctrica a corto, mediano o largo plazo.

### **2.2.1 El pronóstico a corto plazo**

El pronóstico a corto plazo es requerido por los encargados de planificar la operación diaria. Estos pronósticos consisten en proporcionar la demanda de energía eléctrica del sistema sobre un intervalo de horas, días e incluso semanas. El pronóstico desempeña un papel importante en la operación y despacho económico de unidades. [4][5][6].

La demanda de energía eléctrica tiene variaciones las cuales son naturales, esta se ve afectada por varios factores tales como condiciones sociales, meteorológicas y económicas; para las cuales se tienen diferentes afectaciones. Las variaciones sociales y las condiciones económicas no tienen ninguna influencia para este pronóstico, por otra parte, las condiciones climatológicas tienen un papel preponderante en el pronóstico de la demanda a corto plazo. Por lo que la demanda, durante los días laborables se diferencian de los días de fines de semana e igualmente la demanda durante los días de fiesta son diferentes de los de días normales. Por lo que la carga máxima diaria ocurre normalmente alrededor de la temperatura máxima o mínima dependiendo si la energía se requiere para refrescar o calentar. Con lo que se puede decir que la curva diaria de la demanda sigue normalmente el perfil de temperatura diaria.

### **2.2.2 El pronóstico a mediano plazo**

Con el pronóstico de la demanda a mediano plazo, se pronostican los energéticos que son necesarios para mantener la demanda futura, además de proporcionar elementos para llevar a cabo programas de mantenimiento, planear el consumo de combustible requerido por las diversas unidades y una coordinación adecuada de los recursos hidráulicos de las presas. Este pronóstico

consiste en proporcionar la demanda de energía eléctrica en un intervalo que comprende de semanas, meses e incluso hasta 5 años. [4][5][6]

El pronóstico a mediano plazo esta influenciado por muchos más factores aparte de las condiciones atmosféricas. Las variables socioeconómicas también desempeñan un papel importante en el desarrollo de los pronósticos mensuales de la demanda de la energía eléctrica. La inspección de los datos históricos muestra que el patrón del consumo de la demanda de energía, es más o menos cíclico por su propia naturaleza, cambiando únicamente de lugar el pico, debido al crecimiento de la población y por ende el crecimiento de la demanda de energía eléctrica.

Los datos requeridos para el pronóstico de la demanda a mediano plazo, son variables que deben ser elegidas como resultado de un análisis, además de la consulta con los operadores, recomendándose las siguientes: [4][5][6] temperatura máxima absoluta, temperatura media, humedad máxima relativa, velocidad del viento, humedad media, duración brillante de sol, radiación global, precipitación, presión del vapor, días confortables, índice de comodidad, temperatura en la carga máxima, humedad en la carga máxima, y número de la consumidores conectados.

### **2.2.3 El pronóstico a largo plazo**

El pronóstico de la demanda a largo plazo (conocido comúnmente como pronósticos de los máximos anuales de la demanda y de energía) es de gran importancia para la planeación de la creación de nuevas plantas de generación, de redes o líneas de transmisión de energía eléctrica, además del consumo de combustible que se tendrá a largo plazo y la valoración de los costos de producción de la energía eléctrica. El horizonte del pronóstico, para este caso es normalmente de 5 a 25 años. [4][5][6]

El pronóstico a largo plazo de la demanda de energía eléctrica desempeña un papel importante en la planeación del crecimiento de cualquier sistema eléctrico de potencia (SEPs). Por ejemplo, para llevar a cabo la interconexión entre dos o más SEPs, es necesario realizar estudios extensivos, de todas las condiciones que puedan influir en tal proyecto, así como, un estudio de mercado a futuro que respalde por un largo tiempo el capital que se invertirá.

Para este horizonte de tiempo además de las variables usadas para el pronóstico a mediano plazo, las variables que más afectan la demanda. Son las variables socioeconómicas, puesto que consideran el crecimiento de la población el producto interno bruto, por otra parte, las variables meteorológicas dejan de influir para este horizonte de tiempo.

### **2.3 Los factores que afectan la demanda eléctrica**

La demanda de energía eléctrica de un sistema de potencia, es influenciada por varios factores tales como: variables meteorológicas, socioeconómicas y demográficas. De hecho, el número de las variables requeridas depende de la naturaleza del pronóstico, por lo tanto estas variables deben ser seleccionadas cuidadosamente. En el pasado, se sobrestimaba el pronóstico de la demanda de energía, lo cual llevaba a realizar pronósticos rápidos, dando como resultado inversiones de capital en equipo y crecimiento de la red eléctrica, lo cual no sería aprovechado de forma inmediata [5][6][11].

Por lo tanto, estas variables deben ser seleccionadas cuidadosamente, el criterio de selección para estas variables, se podría basar en la intuición humana, lo cual tendría que ser validado tanto por un análisis de correlación como por un análisis de la contribución al pronóstico.

#### **2.3.1 Factores comunes**

Todos los factores, tales como: variables meteorológicas, socioeconómicas y demográficas, actúan directa o indirectamente sobre el patrón de la demanda de energía eléctrica. Algunos de estos factores reflejan cambios importantes en su consumo y en su producción; por lo tanto, la demanda de energía eléctrica de un SEP se ve influenciada por estos factores. Como ejemplo de estas variables, se tienen: la temperatura, la humedad relativa, la velocidad del viento, las nevadas, el nivel de radiación solar, duración del brillo del sol, el índice de la comodidad, número de consumidores conectados, crecimiento de la población y el producto interno bruto [5][6][11].

#### **2.3.2 Factores ocasionales**

Puesto que además de las variables anteriormente dichas, existen algunas variables que ocasionalmente se presentan, las cuales pueden o no provocar alguna influencia sobre el efecto de

la carga, tal como: los festivales, los acontecimientos religiosos, los días de fiesta nacionales, eventos deportivos, huelgas o catástrofes [5][6].

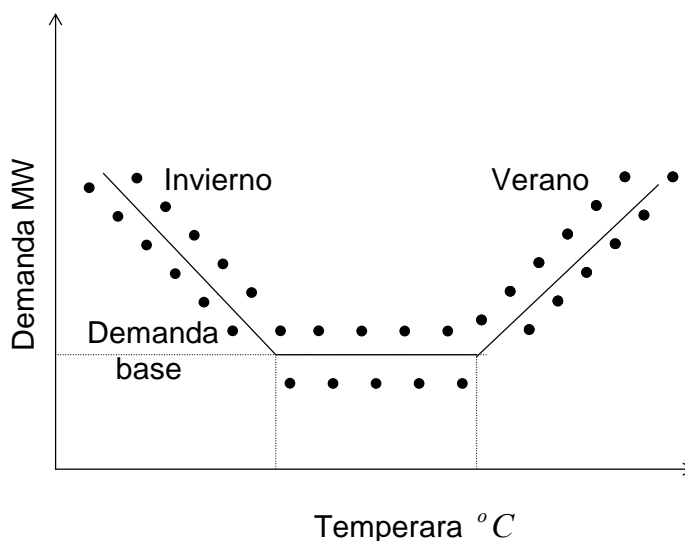


Figura 2.3. Gráfica de la demanda en relación a las estaciones climatológicas

### 2.3.3 Factores estacionales

La demanda eléctrica de un SEP, también es analizado por periodos o etapas, como se puede ver en la figura 2.3. La demanda durante el día se diferencia de la demanda durante la noche, y la demanda durante días laborables, se diferencia de los fines de semana. La demanda en un día extremadamente caliente, se diferencia de uno extremadamente frío. El crecimiento en demanda eléctrica durante un tiempo económico de auge, se diferencia considerablemente de la demanda durante un período de austeridad o recesión [5][6][11].

### 2.4 Los datos históricos

Para el pronóstico de la demanda de energía eléctrica, el papel de la información histórica es vital ya que el éxito o fracaso de un método de pronóstico depende básicamente de la disponibilidad de los datos, tales como los factores comunes y los ocasionales. Algunas otras variables útiles también son obtenidas, sintetizando estas variables. Tal como la desviación de la temperatura diaria promedio, que activa el aire acondicionado. Lo cual está relacionado con el confort [11].

Otros datos que pueden ser considerados, especialmente para los pronósticos de mediano y largo plazo son: las variables socioeconómicas como el producto interno bruto (PIB), la población del área, el crecimiento económico, el número de los consumidores conectados y el nivel industrial de la zona, el número de los nuevos proyectos infraestructurales. La relación entre la demanda y las variables mencionadas, son por su naturaleza no lineales. Por lo que cualquier método de pronóstico buscará de cierta manera, una relación de cualquier variable con la demanda de energía eléctrica.




Figura 2.4 Curva de la demanda de energía eléctrica Zona Norte de la República Mexicana.

## 2.5 La naturaleza de la demanda de energía eléctrica

La demanda de energía en su gran mayoría es cíclica por su propia naturaleza, como se puede ver en el gráfico de la figura 2.4, donde se ve claramente que la curva de la demanda tiene un patrón que se repite sobre los años. La única diferencia es que el pico de la curva está aumentando constantemente cada año, señalando el crecimiento en la demanda. Así, el pronóstico se reduce a un reconocimiento del patrón, para encontrar el crecimiento o tendencia subyacente de la demanda [5][6].

## 2.6 Clasificación de métodos en el pronóstico

En diciembre de 1933, George J. Read de Brooklyn de Edison Company, describió el comportamiento eléctrico y concluyó que: " *el pronóstico de la demanda de energía eléctrica es una necesidad urgente, desafortunadamente la mayoría de los métodos usados para realizar los pronósticos se acompañan por factores que debilitan la credibilidad de este*" [11]. Esta

declaración sigue siendo hoy verdadera y sirve como recordatorio de los problemas y las dificultades de pronosticar la demanda de energía eléctrica.

### 2.6.1 Clasificación general

Todos los tipos y técnicas de pronósticos son por naturaleza extrapolativos, es decir, que incluyen interpolación, o bien predicen con datos existentes, lo cual se puede considerar como extrapolación. Una clasificación general de los métodos de pronóstico sería, que cuando se dispone y se emplea la información histórica, los métodos se llaman *cuantitativos*, y de no ser así, generalmente se les conoce como *métodos cualitativos*, [12][13][20][21] de una manera más precisa se tiene que:

- Los *métodos cuantitativos*, usan la extrapolación de la tendencia, el ciclo y la estacionalidad, basándose en la experiencia. y en métodos estadísticos, fundamentados en modelos probabilísticos que también usan la extrapolación, pero con la idea de minimizar el error del pronóstico, dentro de estos métodos se cuentan con las series de tiempo, modelos de regresión y nuevos métodos.
- Los *métodos cualitativos*, son consecuencia del razonamiento, juicio y experiencias acumuladas por el personal que tiene a su cargo la tarea de realizar el pronóstico. Dentro de estos métodos se practican con mayor frecuencia los métodos de exploración y los normativos. Tales métodos se requieren a menudo cuando los datos históricos no están disponibles o dependen de las opiniones de los expertos.

### 2.6.2 Clasificación según la tendencia

Las metodologías para el pronóstico de la demanda se pueden clasificar en dos amplias categorías: modelos autónomos y modelos condicionales. Siendo los modelos autónomos los que relacionan el crecimiento futuro de la demanda de un sistema basado principalmente en el crecimiento de la propia demanda en los últimos periodos, y los modelos condicionales tratan tentativamente de relacionar el crecimiento de la demanda de energía eléctrica con otras variables [11][13].



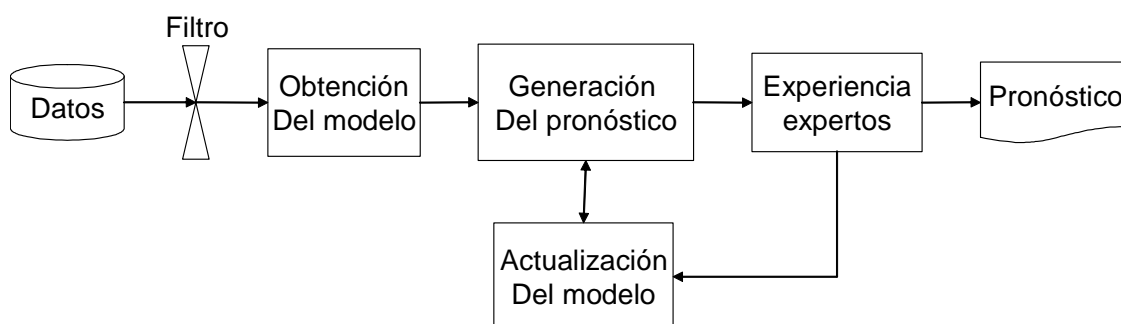
## 2.7 Construcción de un modelo

Antes de construir un modelo de pronóstico, el primer paso es entender claramente el problema para establecer el horizonte de tiempo y los objetivos del pronóstico. Una vez que el problema se determine completamente, se debe centrar la atención en elaborar un plan para el desarrollo de un modelo de pronóstico [4][12][13].

### 2.7.1 Selección de variables

Los requisitos para seleccionar las variables de entrada (Variables dependientes e independientes) apropiadas al modelo propuesto, son los siguientes: [5][6][11][13]

- Seleccionar una lista de posibles variables que podrían contribuir a la demanda eléctrica.
- Que las variables seleccionadas provengan de fuentes confiables.
- Realizar un análisis de las variables propuestas para identificar valores erróneos o la falta de ellos.
- Calcular la correlación entre las variables propuestas y la demanda, la cual debe ser mayor que 10%, de lo contrario no debe ser considerada plenamente.
- Se recomienda que se consulte la opinión de expertos en el área, y colegas con conocimientos en el tema.



*Figura 2.5 Esquema Generalizado de un pronóstico.*

### 2.7.2 Procesamiento de los datos

Durante la tarea de recopilación de datos, se notará que éstos no se encuentran limpios de ruido en su estado natural, es decir, los datos recogidos de las diversas fuentes son generalmente

ruidosos, además de que en ocasiones están mal distribuidos. Estas condiciones, de no tratarse correctamente antes del desarrollo del modelo (figura 2.5), podrían conducir a un pronóstico inexacto o no confiable [11].

## **2.8 Criterios para evaluar el desempeño de los modelos**

Para que el valor de un pronóstico sea aceptable, la credibilidad del mismo debe ser determinada, Así, un modelo de pronóstico debe considerar un conjunto de criterios que se utilizarán para medir el desempeño de este. Cuando un pronóstico especifica los criterios de desempeño, no solamente se validan éstos, si no que establecen normas para pronósticos futuros, además estos criterios sirven para que el usuario conozca la precisión y debilidad de dicho pronóstico [4][5][6][11].

### **2.8.1 Evaluación del modelo**

La evaluación del desempeño de los modelos es de gran importancia en el proceso de pronóstico, y en la medida en que se proporcione información sobre el riesgo asociado al pronóstico o un resumen de los errores del modelo empleado. Será importante al usuario, para conocer la incertidumbre futura del uso de dicho pronóstico, para planear estrategias dentro del rango posible del pronóstico y establecer escenarios basados en distintos supuestos sobre los acontecimientos futuros. Cabe resaltar que detrás de los errores de pronóstico pueden existir distintos problemas, como por ejemplo errores de especificación del modelo, errores en la estimación de los parámetros, perturbaciones atípicas, errores en las proyecciones de las variables independientes y errores de medición de las variables dependientes [12][21].

### **2.8.2 Constancia paramétrica**

Un problema que enfrentan los modelos de pronóstico es que el proceso en análisis pocas veces es estable, lo que lleva a grandes errores. Cuando esto ocurre, los modelos que antes eran exitosos fallan en pronósticos cuando surgen datos atípicos. La constancia paramétrica es esencial para el diseño del modelo. Requiriéndose que los parámetros sean estadísticamente estables. Entonces la evaluación de los diferentes modelos debe dirigirse a probar si el modelo cuenta con una estructura paramétrica razonablemente constante y que sigan siendo útiles aun cuando se

produzcan cambios abruptos en los datos que se analizan. En este sentido la constancia paramétrica es una propiedad deseable. Aunque esto no es suficiente para asegurar que un modelo sea adecuado o no, para fines del pronóstico [12][13].

### 2.8.3 Medidas de precisión

Los pronósticos se expresan tradicionalmente como estimaciones puntuales. Las evaluaciones retrospectivas de estas estimaciones asumen usualmente que la función de pérdida de exactitud, está asociada a los errores del pronóstico y aumenta con una magnitud aritmética del error. Como resultado, existen distintas medidas descriptivas que a menudo son usadas para evaluar los pronósticos. Entre las medidas más comunes tenemos: [12]

- **Error medio**

$$\frac{1}{\tau} \sum_{i=1}^{\tau} e_{(T+i),h} \quad (2.1)$$

Donde  $\tau$  es el número de pronósticos (*durante el ajuste de la curva*) realizados en la comparación y  $h$  es el horizonte temporal de los errores. El error de predicción,  $e_{(T+i)}$ , se define como la diferencia entre el valor real observado de la variable de interés,  $y_{T+h}$ , y la predicción realizada por el modelo correspondiente es,  $\hat{y}_{T+h}$ , de modo que  $e_{T+h} = y_{T+h} - \hat{y}_{T+h}$ .

- **Error absoluto medio**

$$\frac{1}{\tau} \sum_{i=1}^{\tau} |e_{(T+i),h}| \quad (2.2)$$

- **Error absoluto acumulado**

$$\sum_{i=1}^{\tau} |e_{(T+i),h}| \quad (2.3)$$

- **Raíz cuadrada del error cuadrático medio**

$$\sqrt{\frac{1}{\tau} \sum_{i=1}^{\tau} [e_{(T+i),h}]^2} \quad (2.4)$$

## **2.8.4 Comparación y combinación entre modelos de pronóstico**

### **2.8.4.1 Comparación entre modelos**

La comparación entre distintos modelos concierne a la precisión y el contenido informativo. Desde el punto de vista empírico, la primera pregunta que corresponde plantearse es ¿Existe en la medida del error algún dominio claro de un método sobre otro? Cabe precisar que cuando se comparan pronósticos correspondientes a distintos procedimientos o modelos, es necesario considerar todas las dimensiones sobre las que se pretende que los modelos aporten información. Lo ideal es que un modelo domine sobre sus competidores en todas las dimensiones relevantes [20].

### **2.8.4.2 Combinación de modelos**

La combinación de modelos es un procedimiento alternativo que permite comparar su desempeño y al mismo tiempo puede contribuir a mejorar otros pronósticos [11].

En general, se espera que diferentes pronósticos basados en distintos conjuntos de información, modelos, o enfoques de análisis, contribuyan de diferente manera al problema de pronóstico. Por lo tanto, la combinación de modelos puede ser más precisa que lo aportado por cualquiera de ellos por separado. La ventaja de combinarlos consiste en que no se descarten los pronósticos con peor desempeño, ya que los mismos podrían contener información útil para otro modelo [11][12].

Sin embargo, la combinación de modelos es una estrategia ineficiente, en determinadas circunstancias, por ejemplo cuando las restricciones de costos o de tiempo se convierten en un obstáculo para la implementación de esta técnica.

## **2.8.5 Efectividad del método**

La efectividad de un método de pronóstico se debe juzgar no por su funcionamiento en un sólo caso sobre un o dos años, si no por su funcionamiento duradero. Un buen método del pronóstico debe tratar adicionalmente variables tales como: la relación existente entre la demanda, la naturaleza de la demanda, los datos socioeconómicos o la estructura de crecimiento de la demanda [5][6].

## 2.9 Métodos de pronóstico utilizados en este trabajo

En este trabajo se analizarán los métodos de pronóstico para conocer la demanda de energía eléctrica, cada uno implica un grado diferente de complejidad y supone un nivel diferente de comprensión acerca de la demanda de energía eléctrica, a continuación se dará una breve descripción de los métodos de pronóstico de la demanda de energía eléctrica empleados [5][11][12][13]:

### 2.9.1 Regresión lineal

En esta clase de modelos la demanda de la energía eléctrica es explicada por una función única (lineal o no lineal) de un número de variables explicativas. El análisis de regresión tiene por objeto estimar el valor promedio de una o varias variables dependientes o independientes, con base en los valores de una o más variables adicionales o variables explicativas. En este tipo de análisis, la variable dependiente es estocástica mientras que las variables independientes son no estocásticas, en su mayor parte. El análisis de regresión ha cobrado popularidad debido al gran número de paquetes comerciales estadísticos que lo incluyen y por ser un proceso que se adapta a un sinnúmero de aplicaciones que permiten la toma de decisiones [20], el modelo empleado para el pronóstico de la demanda es de la forma:

$$Y_t = B_0 + \sum_{i=1}^p \beta_i X_{ti} + \varepsilon_t \quad (2.5)$$

Donde:  $Y_t$  es la demanda pronosticada para el periodo  $t$ .

$X_{ti}$  es la  $i$ -ésima variable independiente (temperatura, humedad, población, etc.)

$\varepsilon_t$  es el error aleatorio, y  $B_0, B_1, \dots, B_p$  son parámetros desconocidos.

Los métodos de regresión son sencillos y fáciles de aplicar para diferentes tipos de problemas sin embargo, la naturaleza de los datos darán la pauta para aplicar o no una regresión para realizar un pronóstico.

### Programa utilizado

Se desarrolló un programa en lenguaje FORTRAN\_90, para resolver el problema de pronóstico usando este método, el código del programa desarrollado y el manual se encuentra al final de este trabajo ver “Apéndice A y D”, en la figura 2.6, se muestra el diagrama de flujo del programa desarrollado.

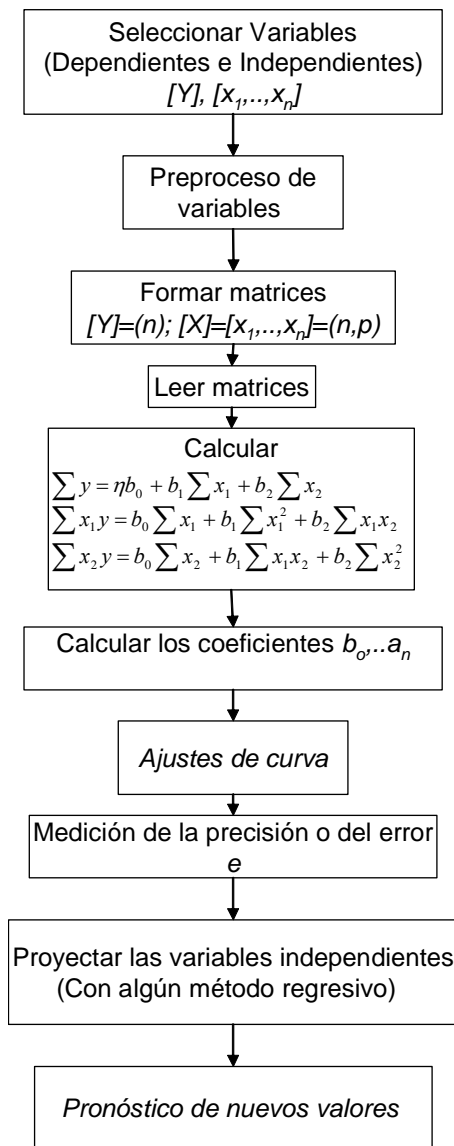


Figura 2.6 Diagrama de flujo del programa de regresión lineal.

## 2.9.2 Métodos autorregresivos

Para dar una introducción a este método, se empezará con las funciones lineales que son relativamente fáciles de tratar. Si se considera una serie de tiempo  $y_t$  unívariable para un pronóstico  $h=1$  períodos en el futuro [21][22], y si:  $\hat{y}_{T+h} = f(y_T, y_{T-1}, \dots)$  se tiene:

$$\hat{y}_{T+1} = v + \alpha_1 y_T + \alpha_2 y_{T-1} + \dots \quad (2.6)$$

Asumiendo un número finito  $p$ , de los últimos valores de  $y$  se tiene:

$$\hat{y}_{T+1} = v + \alpha_1 y_T + \alpha_2 y_{T-1} + \dots + \alpha_p y_{T-p+1} \quad (2.7)$$

Por supuesto, el valor verdadero de  $y_{T+1}$  por lo general no será exactamente igual al pronóstico  $\hat{y}_{T+1}$ . Siendo el error del pronóstico  $e_{T+1} = y_{T+1} - \hat{y}_{T+1}$  de modo que:

$$y_{T+1} = \hat{y}_{T+1} + e_{T+1} = v + \alpha_1 y_T + \dots + \alpha_p y_{T-p+1} + e_{T+1} \quad (2.8)$$

Ahora, si se asume que nuestros valores son variables al azar y que la misma ley de generación de estos datos prevalece en cada período  $T$ ,  $y_{T+1}$  entonces se tiene la forma de un proceso autorregresivo.

$$y_t = v + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + e_t \quad (2.9)$$

Donde  $y_t, y_{t-1}, \dots, y_{t-p}$  y  $e_t$  ahora son variables al azar. Realmente para tener un proceso autorregresivo (AR) asumimos que los errores  $e_t$  del pronóstico de diversos períodos no tienen correlación, es decir,  $e_t$  y  $e_s$  no presentan correlación para  $s \neq t$ . es decir que toda la información útil en  $y_t$  se utiliza para el pronóstico de modo que no haya errores sistemáticos del pronóstico.

Si se considera una serie de tiempo múltiple es obvio que  $\hat{y}_{T+1}$  sería:

$$\hat{y}_{k,T+1} = v_k + \alpha_{k,1} y_{1,T} + \alpha_{k,2} y_{2,T} + \dots + \alpha_{k,K+1} y_{K,T} + \dots + \alpha_{k,1,p} y_{1,T-p+1} + \dots + \alpha_{kK,p} y_{K,T-p+1}, \quad (2.10)$$

Donde:  $k=1, \dots, K$

Para simplificar la notación tenemos;

$$y_t := (y_{1t}, \dots, y_{Kt})', \hat{y}_t := (\hat{y}_{1t}, \dots, \hat{y}_{Kt})', v := (v_1, \dots, v_K)' \text{ y}$$

$$A_i := \begin{bmatrix} \alpha_{11,i} & \cdots & \alpha_{1K,i} \\ \cdot & \cdots & \cdot \\ \cdot & \cdots & \cdot \\ \alpha_{K1,i} & \cdots & \alpha_{KK,i} \end{bmatrix}$$

Entonces  $\hat{y}_{k,T+1}$  se puede escribir como:

$$\hat{y}_{T+1} = v + A_1 y_T + \dots + A_p y_{K,T-p+1}, \quad (2.11)$$

Si  $y_t$  se toma al azar los vectores encontrados, resultan ser el pronóstico óptimo del modelo del vector autorregresivo (*VAR*) de la forma:

$$y_T = v + A_1 y_{T-1} + \dots + A_p y_{T-p} + e_t, \quad (2.12)$$

Donde  $e_t = (e_{1t}, \dots, e_{Kt})'$  forma una secuencia de *K*-vectores al azar independientes e idénticamente distribuidos.

Tal modelo representa obviamente una enorme simplificación comparada con la forma general  $\hat{y}_{k,T+h} = f(y_{1,T}, \dots, y_{K,T}, y_{1,T-1}, \dots, y_{K,T-1}, \dots)$ . Debido a su estructura simple, este método tiene gran aplicación para la solución de este problema. Este modelo en particular será empleado en la mayoría de los ejemplos que en este trabajo se realicen [22][23].

Si se asume que el orden del modelo es *n*, para *VAR*, se puede utilizar para estimar los coeficientes  $a_1, \dots, a_p$ , donde los modelos *VAR* se expresan en forma de vector como a continuación se presenta: [12] [13]

$$\begin{bmatrix} y(n+1) \\ y(n+2) \\ \cdot \\ \cdot \\ y(N) \end{bmatrix} = \begin{bmatrix} y(n) & y(n-1) & \cdots & y(1) \\ y(n+1) & y(n) & \cdots & y(2) \\ \cdot & \cdot & \cdots & \cdot \\ \cdot & \cdot & \cdots & \cdot \\ y(N-1) & y(N-2) & \cdots & y(N-n) \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \cdot \\ \cdot \\ \alpha_3 \end{bmatrix} + \begin{bmatrix} e(n+1) \\ e(n+2) \\ \cdot \\ \cdot \\ e(N) \end{bmatrix}$$

O bien de la forma

$$y = Ha + e \quad (2.13)$$

Obviamente, la mejor estimación de *a* se da en:

$$\hat{\alpha} = (H^T H)^{-1} H^T y \quad (2.14)$$



### Programa utilizado

Se desarrolló un programa en lenguaje FORTRAN\_90, para resolver el problema de pronóstico usando este método, el código del programa desarrollado y su manual de funcionamiento se encuentra al final de este trabajo. Ver “Apéndice B y E” en la figura 2.7 se muestra el diagrama de flujo del programa desarrollado.

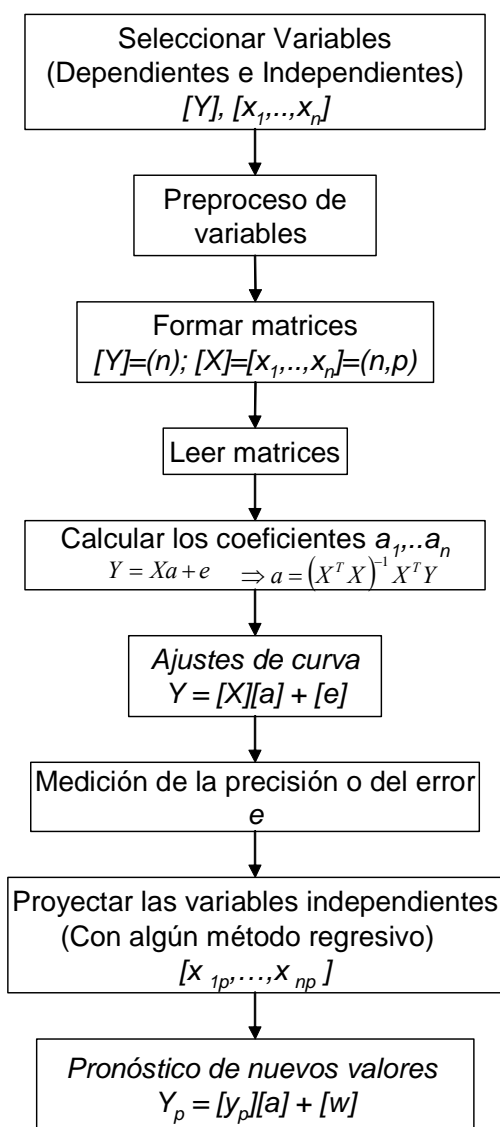


Figura 2.7 Diagrama de flujo del programa del método autorregresivo.

### 2.9.3 Redes neuronales artificiales

El hombre se ha caracterizado siempre por su búsqueda constante de nuevas tecnologías para mejorar sus condiciones de vida. Estos esfuerzos le han servido para reducir el tiempo en operaciones en las que este factor juega un papel primordial. Los progresos obtenidos, han permitido dirigir estos esfuerzos a otros campos, como por ejemplo, la optimización de métodos de pronóstico que ayudan a resolver de forma casi automática y de manera además rápida determinadas operaciones que resultarían tediosas, si se realizan por otros métodos [3][7][8].

Por lo tanto, las redes neuronales son más que otra forma de emular las características propias del cerebro humano, o la capacidad de memorizar y de asociar hechos. Si se examinan con atención aquellos problemas que no pueden expresarse a través de un algoritmo, se observará que todos ellos tienen una característica en común: la experiencia. El hombre es capaz de resolver estas situaciones acudiendo a la experiencia acumulada. Así pues, parece claro que una forma de aproximarse al problema, consiste en la construcción de sistemas que sean capaces de reproducir esta característica humana. En definitiva, las redes neuronales no son más que un modelo artificial simplificado del cerebro humano, este sistema es capaz de adquirir conocimiento a través de la experiencia.

Las redes neuronales no son un método nuevo para el tratamiento y análisis de información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano siendo esta “*la neurona*”, este método por ser el punto principal de este trabajo, se explica a detalle en el siguiente capítulo.


# CAPÍTULO III

## **METODOLOGÍA DE LA RED NEURONAL ARTIFICIAL POR RETROPROPAGACIÓN**

### 3.1 Introducción

Las redes neuronales artificiales RNA como su nombre lo indica pretenden emular la forma del funcionamiento del cerebro humano [24]. Como se trata de ejemplificar en la figura 3.1.

Entre los pioneros en el modelado de neuronas artificiales, se encuentra Warren McCulloch y Walter Pitts. Estos dos investigadores propusieron un modelo matemático de neurona, donde cada neurona está dotada de un conjunto de entradas y salidas. Cada entrada está afectada por un peso. Las entradas son modificadas por el peso y las salidas son función de estas modificaciones. Cuando se tienen interconectadas muchas neuronas artificiales, lo que se hace inicialmente es “entrenar” el sistema. El entrenamiento consiste en aplicar unas entradas determinadas a la red y observar la salida que se produce. Si la salida que se produce no se adecua a la salida esperada, se ajustan los pesos de cada neurona de manera interactiva para ir obteniendo las respuestas deseadas. La red se somete a varios ejemplos representativos, de forma que, mediante la modificación de los pesos de cada neurona, se dice que la red está “aprendiendo” [24][25].

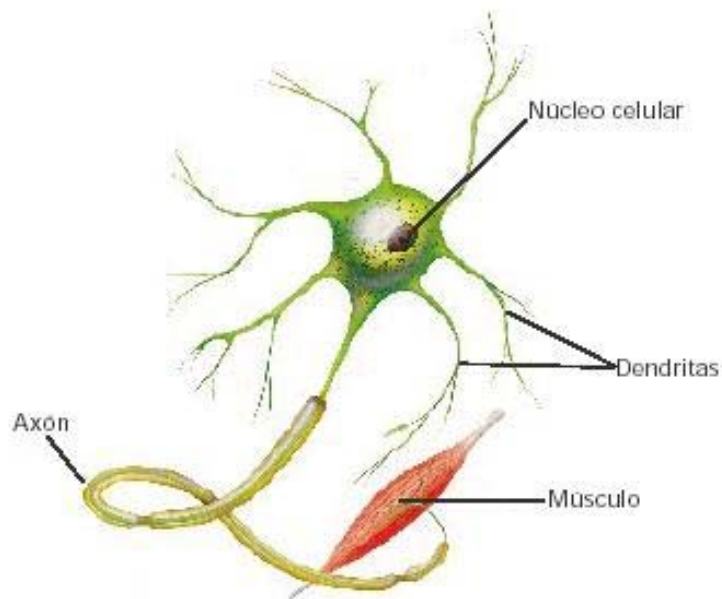


*Figura 3.1: El Cerebro Humano y la RNA.*

### 3.1.1 La neurona biológica

La estructura de una neurona, el tamaño y su forma pueden ser variables, pero todas tienen las mismas subdivisiones que se muestran en la figura.3.2 subdividiéndose así en tres partes [26]:

- El *cuerpo de la neurona*, contiene el núcleo, que se encarga de todas las actividades metabólicas de la neurona y recibe la información de otras neuronas vecinas a través de las conexiones sinápticas.
- Ramas de extensión llamadas *dendritas*, son parte del núcleo y tienen ramificaciones. Éstas se encargan de la recepción de señales de otras neuronas a través de conexiones llamadas *sinapsis*.
- El *axón*, es la salida de la neurona y se utiliza para enviar impulsos o señales a otras células nerviosas.



*Figura 3.2: Neurona biológica.*

La transmisión de una señal de una neurona a otra por medio de la sinapsis es un proceso químico. El efecto es elevar o disminuir el potencial eléctrico dentro del cuerpo de la neurona receptora. Si su potencial alcanza el umbral, se envía un pulso o potencial de acción por el axón. Se dice entonces, que la célula se disparó.

### 3.1.2 La neurona artificial

La neurona artificial se puede considerar como un circuito eléctrico que realiza la suma ponderada de las diferentes señales que recibe de otras unidades iguales, produciendo la salida según el resultado de la suma con relación al umbral o nivel de disparo, en relación a la función de transferencia o de la activación pudiendo ser del tipo *escalón*, *lineal* o *sigmoideal* [24] [27].

### 3.1.3 Un modelo de neurona artificial

Una neurona es un elemento de procesamiento de la información que juega un papel fundamental en la red neuronal. En la figura 3.3 se puede observar un modelo de neurona con sus tres elementos fundamentales [24][25]:

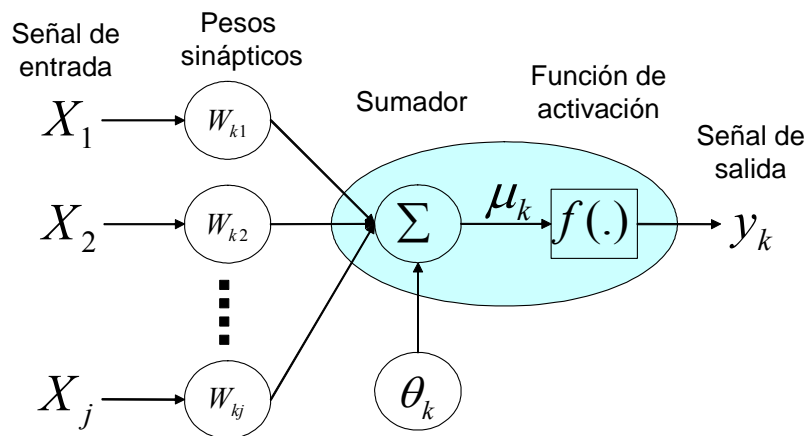


Figura 3.3. Neurona artificial.

1. Un conjunto de *sinapsis* o *conexiones*, se caracteriza por su fuerza o peso. Así, una señal de entrada  $x_j$  después de pasar la conexión, se habrá convertido en una señal  $x_j w_{kj}$ , donde  $w_{kj}$  es el peso o fuerza de la conexión con la entrada  $j$ -ésima de la neurona  $k$ .
2. Un *sumador*  $\Sigma$ , realiza la suma ponderada de las entradas de acuerdo a los correspondientes pesos de las conexiones.
3. Una *función de activación* o *transferencia*, que tiene como misión limitar la amplitud de la salida generada por la neurona.

Es habitual la inclusión en el modelo de un *umbral o polarización* representado por  $\theta_k$ , cuya misión es controlar la tendencia sobre la cual la neurona produce su salida. El término  $\theta_k$  es añadido a la suma, que posteriormente, es transformada por la función de activación  $f()$ .

De acuerdo con este modelo (Figura 3.3), se puede describir el comportamiento de la neurona mediante las siguientes expresiones [24][25][27]:

$$\mu_k = \sum_{j=1}^p w_{kj} x_j \quad (3.1)$$

$$v_k = \mu_k - \theta_k \quad (3.2)$$

$$y_k = f(v_k) \quad (3.3)$$

Otra manera más compacta de decir lo mismo es:

$$y_k = f\left(\sum_{j=0}^p w_{kj} x_j - \theta_k\right) \quad (3.4)$$

La función de activación  $f()$  determina el nivel de activación de la neurona en términos de la actividad existente en sus entradas. Hay una infinidad de funciones para ser utilizadas como función de activación, pero se pueden distinguir tres grandes clases: tipo escalón, lineal y sigmoide. La elección de la función de activación depende fuertemente del algoritmo de aprendizaje que se vaya a utilizar [24][27].

### 3.2 Conceptos y definiciones

Muchas veces se habla de la arquitectura de una red neuronal. Este concepto se refiere básicamente a la manera en que se interconectan los distintos elementos de proceso que forman la red. En la arquitectura de redes neuronales se puede hacer la siguiente distinción entre las capas [24][25][27]:

- *Capa de entrada.* Es la capa que recibe los estímulos del entorno.
- *Capa de salida.* Es la capa sobre la que se forman las salidas de la red.
- *Capas ocultas.* Son las demás capas que no son ni de entrada ni de salida.

### 3.2.1 Paradigmas de aprendizaje

Se denomina paradigma de aprendizaje al modelo del entorno en el que la red neuronal trabaja. Una de las principales ideas sobre las que se basan las redes neuronales artificiales es responder a los estímulos del entorno mediante un proceso de aprendizaje, por el cual se van adaptando los pesos de las conexiones de sus elementos de proceso, de tal forma que la RNA “aprende” de los ejemplos de entrenamiento que se le presentan [24][25].

El paradigma de aprendizaje indica la forma en que el entorno influye en ese proceso de aprendizaje. Así, este paradigma puede ser de la siguiente forma [27]:

- *Supervisado*. Se presentan los conocimientos en forma de pares de *[entrada, salida deseada]*.
- *No supervisado*. Durante este proceso de aprendizaje a la red no se le presenta la salida deseada.
- *Por refuerzo*. Para este proceso sólo se indica cuando la salida es correcta o no, pero no indica en cuanto se diferencia de la salida buscada.
- *Aprendizaje híbrido*. Se trata de una combinación del aprendizaje supervisado y del no supervisado.

### 3.2.2 Modo de operación

Al hablar de modo de operación, se está haciendo referencia a la manera en que la red neuronal procesa los estímulos externos y crea la respuesta de salida. Puede considerarse a una red neuronal como perteneciente a una de las siguientes categorías [24][25]:

- *Estáticas*. Estas redes pueden caracterizarse estructuralmente por la inexistencia de bucles de realimentación y de elementos de retardo entre los distintos elementos de proceso que las forman. Teniendo una capacidad limitada para sintetizar funciones dependientes del tiempo.
- *Dinámicas*. Este tipo responde de manera diferente ante diferentes secuencias de entradas, haciendo uso de manera implícita o explícita de la variable tiempo. Este aspecto la hace en principio más idónea que las redes estáticas para la síntesis de funciones en las que aparezca de alguna manera el parámetro tiempo.



### 3.2.3 Operaciones de las capas

Se trata de operaciones que afectan a la capa como un todo. En principio se considerarán [24][25][27]:

- *La normalización.* Para cada elemento del proceso de la capa se considera su salida para dar un nivel constante de actividad.
- *La competencia.* Sólo uno o unos pocos elementos de proceso de una capa ganan y producen salida, inhibiendo la generación de las salidas en el resto de elementos.

### 3.3 El perceptrón

El Perceptrón, es un modelo de red neuronal muy simple, con lo que no se pueden llevar a cabo de una manera correcta los objetivos de *reconocimiento de patrones*. Sin embargo, este modelo sirvió para que se crearan los principios sobre los que se fundamentan las redes neuronales actuales, especialmente lo concerniente a la estructura y funcionamiento de los elementos de proceso [24][25][27].




Figura 3.4. La red Perceptrón.

### 3.3.1 La red perceptrón

El modelo de una red perceptrón, se puede ejemplificar con la retina del ojo humano (figura 3.4), básicamente las funciones de las distintas capas, son [24]:

- La capa de entrada. Recoge las señales o estímulos en la entrada.
- La capa oculta, detecta rasgos específicos.
- La capa de salida, contiene los reconocedores de patrones.

### 3.3.2 La red multicapa

Como se acaba de ver, el Perceptrón sólo puede solucionar problemas linealmente separables que, obviamente, resultan ser un caso muy particular de los problemas reales. La pregunta que surge es ¿Será posible la combinación en varias capas de elementos de proceso tipo perceptrón?, y si es así, ¿cómo se podría entrenar el sistema?. Lo que se buscaría con una combinación de elementos tipo perceptrón en varias capas, es la división del espacio de entradas en varios subespacios, cada uno de ellos representando una característica del problema a tratar. Luego, en capas posteriores se irían delimitando más detalladamente las distintas zonas del espacio de características, así hasta conseguir la salida deseada [24][25][27].

El ajuste de pesos en el perceptrón se realiza acorde a si la salida generada por dicho elemento de proceso, es correcta o no. Cuando se combinan varios perceptrones formando una estructura en varias capas, la única que tiene definida su verdadera salida, es la capa de salida ya que la podemos comparar con la salida verdadera, la cual sería entonces la única que podría ser ajustada. ¿Qué hacer entonces con las demás capas? La respuesta se da con el algoritmo de *retropropagación del error*, que resulta ser una generalización del método del gradiente decreciente. Pero para poder aplicar la regla del gradiente decreciente, es preciso que la función de activación involucrada sea diferenciable.

### 3.3.3 Algoritmo de retropropagación del error

El algoritmo de aprendizaje de retropropagación del error es una aplicación del bien conocido método del *gradiente decreciente*. Esta regla de aprendizaje, se establece como función objetivo a minimizar el error cuadrático siendo:[27]

$$E(t) = \frac{1}{2} \sum_{i \in \text{capa}'\text{salida}} (y'_i(t) - y_i(t))^2 \quad (3.5)$$

Donde:  $y_i(t)$  es la salida del elemento de proceso  $i$  en el instante  $t$ .

$y'_i(t)$  es la salida deseada para el elemento de proceso  $i$  en el instante  $t$ .

De acuerdo con esta regla de aprendizaje, el peso  $w_{ij}$  que conecta el elemento de proceso  $j$  con el  $i$  se ajusta por:

$$\Delta w_{ij}(t) = \alpha \delta_i(t) y_j(t) \quad (3.6)$$

Donde:  $\alpha$  es el denominado *factor ó coeficiente de aprendizaje* .

$\delta_i(t)$  es la señal de error del elemento de proceso  $i$  en el instante  $t$ .

Si el elemento de proceso  $i$  es de la capa de salida, se tiene que:

$$\delta_i(t) = (y'_i(t) - y_i(t)) f'_i(t) \quad (3.7)$$

Donde  $f'_i(t)$  es la derivada de la función de activación o transferencia en el instante  $t$  para el elemento de proceso  $i$ . Entonces la señal de error tiene el siguiente valor [28]:

$$\delta_i(t) = f'_i(t) \sum_{h=1}^N \delta_h(t) w_{hi} \quad (3.8)$$

Donde  $N$  es el número de elementos de proceso en la capa destino.

En la práctica para acelerar la convergencia se suele introducir un término *momento*:

$$\Delta w_{ij}(t) = \alpha \delta_i(t) y_j(t) + m(w_{ij}(t) - w_{ij}(t-1)) \quad (3.9)$$

Donde  $m$  es el *término momento*. Si se expande el término  $w_{ij}(t)$  en función de todos los valores anteriores, se tiene:

$$\begin{aligned}
 \Delta w_{ij}(t) &= \alpha \delta_i(t) y_j(t) + m \Delta w_{ij}(t-1) \\
 \Delta w_{ij}(t) &= \alpha \delta_i(t) y_j(t) + m \alpha \delta_i(t-1) y_j(t-1) + m^2 \Delta w_{ij}(t-2) \\
 &\bullet \\
 &\bullet \\
 \Delta w_{ij}(t) &= \alpha \sum_{l=0}^t m^l \delta_i(t-l) y_j(t-l)
 \end{aligned} \tag{3.10}$$

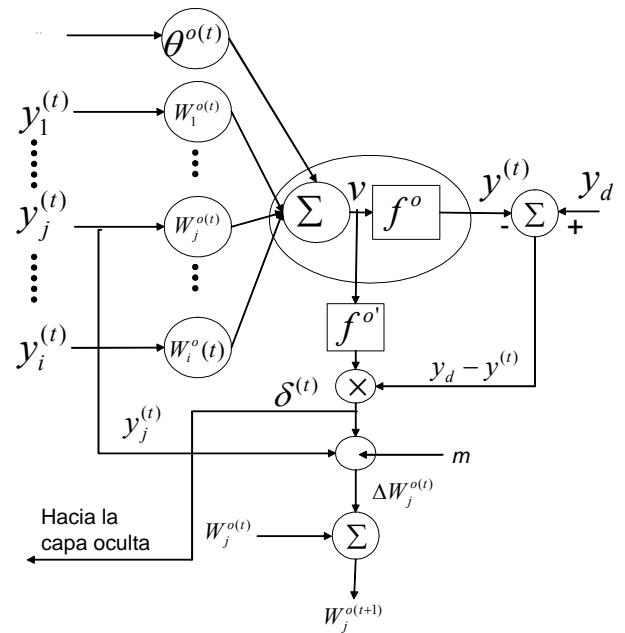
Esta última ecuación representa una serie temporal que converge sólo si el parámetro  $m$  cumple que  $0 \leq |m| < 1$ .

Una variación muy interesante del algoritmo de retropropagación del error, es el que incluye un término de regularización, cuya misión es introducir la condición adicional de minimizar los valores absolutos de los pesos. El añadido de este término, logra minimizar el efecto del *sobreentrenamiento*. En este caso, la expresión para la función de error queda:

$$E(t) = \frac{1}{2} \left( \sum_{i \in \text{capa salida}} (y_i(t) - y'_i(t))^2 + \gamma \sum_{\forall \text{ pesos}} w_{ij}^2 \right) \tag{3.11}$$

Donde  $\gamma$  es la constante de regularización. De este modo, la expresión para la actualización de los pesos queda así:

$$\Delta w_{ij}(t) = \alpha \delta_i(t) y_j(t) + m \Delta w_{ij}(t-1) + \gamma w_{ij}(t) \tag{3.12}$$



*Figura 3.5. Representación del flujo de la información de la RNA por retropropagación.*

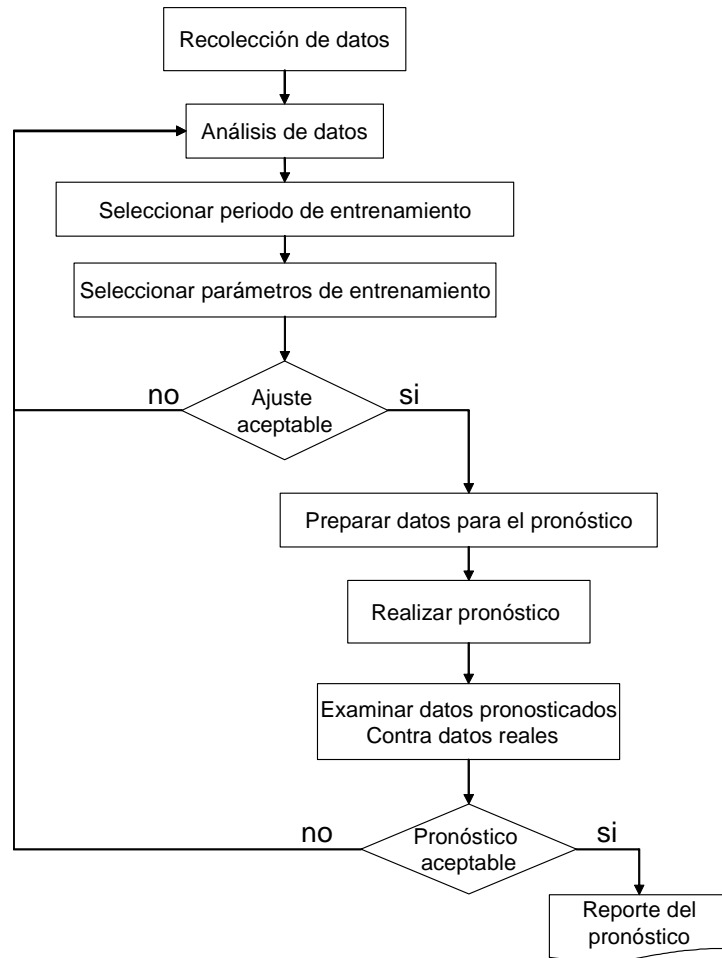


Figura 3.6. Diagrama de flujo del programa de RNA por retropropagación.

### 3.3.4 Coeficiente de aprendizaje

La elección del valor del coeficiente de aprendizaje en el algoritmo de retropropagación del error, está condicionado por dos efectos contrapuestos [24][27]:

- Cuando el valor del coeficiente de aprendizaje es grande, las actualizaciones en los valores de los pesos se producen a incrementos mayores, lo que en principio podría inducir a pensar en una convergencia más rápida. Sin embargo, es posible que no converja.
- Cuando el valor del coeficiente de aprendizaje es pequeño, la aproximación a los puntos de error mínimo es más uniforme, y se tienen más garantías de alcanzar los puntos de error mínimo deseados.

### **3.3.5 Elección de Parámetros**

La elección de la mayoría de los parámetros que intervienen en la definición y ajuste de los sistemas bajo estudio, se llevan a cabo con experimentos piloto; de una manera totalmente arbitraria, y quizás orientado por la experiencia del que diseña la red. Se elige un conjunto de parámetros de partida, y con ellos se crea y evalúa la habilidad de aprendizaje, repitiendo este procedimiento para otros valores con diferentes parámetros [9][29].

### **3.3.6 Diagrama de flujo del modelo empleado**

Se desarrolló un programa en lenguaje FORTRAN\_90, para resolver el problema de pronóstico, usando el método de redes neuronales artificiales por retropropagación del error; el código del programa desarrollado se encuentra al final de este trabajo, ver “Apéndice C y F”, se explica la operación del mismo, así mismo en la figura 3.6 se presenta el diagrama de flujo, para el cual se desarrolló dicho programa.

## **3.4 Aplicación de Redes neuronales**

Las redes neuronales pueden utilizarse en un gran número y variedades de aplicaciones, tanto comerciales como militares. Se pueden desarrollar redes neuronales en un periodo de tiempo razonable, con la capacidad de realizar tareas concretas y mejorar otras tecnologías. Además alcanzar una alta tolerancia a errores del propio sistema y proporcionar un alto grado de paralelismo en el procesamiento de datos. Esto hace posible la inserción de redes neuronales en sistemas y procesos diversos [9][25][29][30].

### **3.4.1 Aplicaciones generales**

Las aplicaciones generales de las redes neuronales se pueden clasificar de la siguiente forma:

#### **✓ Asociación y clasificación de patrones**

En esta aplicación, los patrones de entrada estáticos o series de tiempo, deben ser clasificados o reconocidos. Idealmente, un clasificador debe ser entrenado para que cuando se le presente una versión distorsionada ligeramente del patrón, pueda ser reconocida correctamente sin problemas.

De la misma forma, la red debe presentar cierta inmunidad contra el ruido: esto es, debe ser capaz de recuperar una señal "limpia" de ambientes o canales ruidosos. Esto es fundamental para estas aplicaciones [9][24][25][27]:

✓ **Regeneración de patrones**

En muchos problemas de clasificación, una cuestión a solucionar, es la recuperación de información; esto es, recuperar el patrón original dada solamente una información parcial. El uso apropiado de la información contextual, es la llave para tener éxito en el reconocimiento. [24][25][27]:

✓ **Generalización**

El objetivo de la generalización, es dar una respuesta correcta a la salida para un estímulo de entrada que no ha sido entrenado con anterioridad. El sistema debe inducir la característica saliente del estímulo a la entrada y detectar la regularidad. Tal habilidad para el descubrimiento de esa regularidad, es crítica en muchas aplicaciones. Esto hace que el sistema funcione eficazmente en todo el espacio de tiempo, incluso cuando ha sido entrenado por un conjunto limitado de ejemplos. [24][25][27]:

✓ **Optimización**

Las Redes Neuronales son herramientas útiles en la optimización de aplicaciones, que normalmente implican la búsqueda de un mínimo absoluto de una función particular. Para algunas aplicaciones, esta función es fácilmente deducible; pero en otras, se obtiene bajo criterios y limitaciones especiales. [9][15][25]:

### **3.4.2 Principales aplicaciones**

La mayoría de estas aplicaciones consisten en realizar un reconocimiento de patrones, como es: buscar un patrón en una serie de ejemplos, completar una señal a partir de valores parciales o reconstruir el patrón correcto partiendo de uno distorsionado. Sin embargo, está creciendo el uso de las redes neuronales en distintos tipos de sistemas. Existen diferentes tipos de redes

neuronales; y cada una de las cuales tiene una aplicación particular apropiada. Algunas de las aplicaciones más comunes son [24][25][27]:

#### **3.4.2.1 Biológicas**

- Aprender más acerca del cerebro y otros sistemas.
- Obtención de modelos de la retina.

#### **3.4.2.2 Empresariales**

- Evaluación de probabilidades.
- Identificación de candidatos para posiciones específicas.
- Explotación de bases de datos.
- Optimización de plazas y horarios.
- Optimización del flujo de tránsito controlando.
- Modelado de sistemas para automatización y control.
- Diseño y fabricación.
- Robots automatizados y sistemas de control (sensores de presión, temperatura, gas, etc.).
- Control de producción en líneas de procesos.
- Inspección y control de la calidad.

#### **3.4.2.3 Finanzas**

- Previsión de la evolución de los precios.
- Valoración del riesgo de créditos.
- Identificación de falsificaciones.
- Análisis de mercados.

#### **3.4.2.4 Medicina**

- Diagnóstico y tratamiento a partir de síntomas.
- Predicción de reacciones adversas en los medicamentos.
- Síntesis de nuevos medicamentos.



### **3.4.2.5 Militares**

- Clasificación de señales de radar.
- Creación de armas inteligentes.
- Optimización de recursos humanos y materiales.
- Reconocimiento y seguimiento de blancos.
- Guiado automático de misiles.
- Combate aéreo.
- Selección de rutas.
- Detección de enervantes.

### **3.4.2.6 Otros**

- Reconocimiento de caracteres escritos.
- Reconocimiento de imágenes.
- Conducción de camiones.
- Reconocimiento de voz.
- Interpretación de firmas.
- Análisis de tendencias y patrones climáticos.
- Previsión del tiempo.

### **3.4.3 Aplicaciones en ingeniería eléctrica**

Las aplicaciones que a continuación se presentan representan una serie de problemas típicos en ingeniería eléctrica, los cuales pueden ser resueltos por métodos tradicionales, el objetivo de emplear RNA en la solución de estos problemas, es ofrecer alternativas novedosas que signifiquen una comparación con los métodos tradicionales:

- Flujos de potencia. [30]
- Problemas de programación lineal. [24][27][30]
- Fallas en motores eléctricos. [25]
- Control del giro de un motor de inducción. [9]
- Filtro adaptable. [9]

- Control de voltaje por inyección de reactivos. [9]
- Reconfiguración de un alimentador primario. [9]
- Identificación de un sistema dinámico no lineal. [9]
- Control de hornos de fundición y [25]
- ***Pronóstico de la demanda de energía eléctrica.*** [3][7][8][9][24][25][30][31][32][33][34][35][36]

Este último es el centro de este trabajo y se llevará cabo en el siguiente capítulo, realizando diversas comparaciones con otros métodos para establecer las bondades de llevar a cabo el pronóstico de la demanda utilizando redes neuronales artificiales.

# CAPÍTULO IV

## **PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA UTILIZANDO UNA REDE NEURONAL ARTIFICIAL POR RETROPROPAGACIÓN.**

## **4.1 Introducción**

El pronóstico de la demanda de energía eléctrica, no es una tarea fácil. Un buen analista debe contar con elementos que le permitan conocer el comportamiento del sistema eléctrico, además del conocimiento de las variables independientes que influyen directa o indirectamente en el comportamiento de la demanda. Las redes neuronales artificiales cuentan con el potencial para realizar este tipo de análisis, ya que en la mayoría de los casos son eficientes en el reconocimiento de patrones complejos, que es básicamente el pronóstico de la demanda.

El pronóstico de la demanda de energía eléctrica refleja las necesidades futuras de una población, este pronóstico se debe ajustar lo más posible a la realidad, ya que valores inferiores a los reales causarán deficiencias en la prestación del servicio en un futuro cercano y un pronóstico de necesidades superior al real, motiva una inversión prematura en instalaciones que no tendrán un aprovechamiento inmediato.

### **4.1.1 Selección de variables**

El primer punto y antes de entrar en el problema del pronóstico, consiste en la disponibilidad de los datos que se puedan emplear, la empresa eléctrica puede proporcionar un banco de datos, lo suficientemente nutrido en cuanto a la demanda de energía eléctrica histórica de cualquier región; sin embargo, posiblemente la compañía eléctrica no cuente con la información climatológica, poblacional o económica, esta información de no ser facilitada por la misma compañía, habrá que buscarla en institutos o dependencias que cuenten con la citada información, una vez con la información se deberá analizar ésta, para seleccionar y emplear las variables útiles al problema del pronóstico.

### **4.1.2 Preprocesamiento**

Se denomina preprocesamiento al tratamiento previo de los datos de entrada y salida para adecuarlos al entrenamiento de la red neuronal. Este proceso es aconsejable aunque tal vez no imprescindible, con el preprocesamiento se busca obtener las siguientes cualidades [22]:

- Distribución estándar o uniforme.
- Rangos de valores parecidos para todas las variables.
- Rangos acotados dentro del intervalo de trabajo de la función de activación empleada en la red.

Para modificar el rango de valores de las entradas se aplica un estandarizado. El objetivo es acotar sus valores entre los límites de la función de activación seleccionada, esto para evitar la saturación de las neuronas de la red, al realizar la suma ponderada de las entradas. Para ello se busca el mínimo y máximo del rango de las entradas y se transforma el intervalo al comentado anteriormente. La forma de obtener factores estandarizados para nuestro fin, es:

Tratar a la demanda y a cada variable independiente por separado aplicando de forma sucesiva el preprocesamiento antes explicado, con esto se está uniformando el rango de variación de todas las entradas y por lo tanto, se equipara su importancia; es decir, los valores de población que son del orden de millones de personas, los de temperatura que oscila de 5 a 25 °C, los índices de humedad de 30 a 50 y los valores de la demanda del orden de MWh. Son estandarizados en un rango de [0 a 1].

$$x_i' = \frac{x_i - x_{menor}}{\sigma} \quad \text{ó} \quad x_i' = x_i - x_{menor} \quad (4.1)$$

Posteriormente


$$x_i'' = \frac{x_i'}{x'_{mayor}} \quad (4.2)$$

### 4.1.3 Ajuste

El ajuste de los datos de las siguientes simulaciones, se realizará para mejorar el desempeño del pronóstico. Es decir, que el comportamiento de un modelo dinámico inclina a que el pronóstico sea inestable, ya que pueden existir cambios, cualquier sesgo o dato atípico en la información analizada, que pueda derivar en un pronóstico subestimado o sobrestimado, lo cual se puede verificar durante el ajuste, este proceso representa el primer paso para comparar los distintos métodos y seleccionar el mas próximo a la realidad. Aunque cada situación es distinta y cada uno de los métodos difieren entre si. El ajuste es de gran ayuda para identificar las características generales de cada método.

#### 4.1.4 Pronóstico

Una vez establecidas las características o criterios de los métodos dichos, se puede utilizar el ajuste como marco de referencia básico para adecuar necesidades y objetivos específicos, en este sentido es útil mantener firmemente dichas características presentes, antes de seleccionar el método para obtener el pronóstico. El siguiente paso al ajuste de la curva, es obtener el pronóstico deseado, la aplicación de este pronóstico reconoce la importancia de seleccionar la técnica de pronóstico apropiada.



*Figura 4.1. Esquema de la RNA empleada.*

#### 4.2 Definición del modelo de RNA a utilizar

El desarrollo de las aplicaciones utilizando redes neuronales artificiales, es muy extenso y son lo suficientemente eficientes para resolver problemas donde se necesitan aproximaciones a funciones, La RNA basa su funcionamiento en la topología, algoritmo de entrenamiento y los datos empleados para entrenarla.

### **4.2.1 Justificación del tipo de red**

El algoritmo de retropropagación hacia atrás, es un algoritmo que necesita conocer la salida esperada (demanda real) la cual se asocia a cada una de las entradas (demanda, temperatura, humedad, población o radiación solar), para actualizar los pesos de cada capa, siguiendo la regla delta decreciente descrita en el capítulo 3.

Una de las mayores ventajas de la red de retropropagación hacia atrás, consiste en que pueden aproximar una función, si se escoge una adecuada configuración para la red y un adecuado número de neuronas en cada capa, esto depende de la experiencia del desarrollador de la red. Es decir, la red de retropropagación hacia atrás es un excelente ajustador de funciones, aunque es difícil determinar una configuración exacta de la red para cada aplicación.

Un claro ejemplo de la red puede observarse en la figura 4.1, en la cual se muestran los datos de entrada y salida de la red. Allí puede verse cómo ingresan a la red todas las variables, con las cuales se desea entrenar la red en cuestión para conocer el valor de la demanda de energía eléctrica de acuerdo a los valores históricos. Las condiciones de entrada a la red pueden ser tan complejas como se quiera.

### **4.2.2 Proceso de entrenamiento**

El proceso de entrenamiento no es fijo para ninguna red neuronal, el éxito consiste en probar con diferentes configuraciones, hasta obtener la respuesta deseada; para este trabajo se emplearon diferentes redes de prueba desde una sola neurona hasta redes de tres capas con 50 neuronas en la capa oculta, hasta que se obtuvo una respuesta lo más próxima a la realidad, con lo cual se estableció el entrenamiento de la red.

### **4.2.3 Valores utilizados en el pronóstico**

Para este trabajo, se buscó establecer la importancia que tiene cada variable, en relación a la influencia sobre la demanda de energía eléctrica; por lo tanto y siguiendo este objetivo se realizaron para cada uno de los métodos analizados las siguientes pruebas:

- ✓ Primera, se utilizó la demanda real y la temperatura media mensual.
- ✓ Segunda, se utilizó la demanda real y la humedad media mensual.
- ✓ Tercera, se utilizó la demanda real y el crecimiento mensual de la población.
- ✓ Cuarta, se utilizaron los datos de la demanda real y todas las variables independientes.
- ✓ Quinta, se efectuó el entrenamiento en cascada, es decir se realizaron varios entrenamientos primero la demanda real más una variable, al ajuste de éste se le agregó otra variable y así sucesivamente hasta terminar el entrenamiento de todas las variables, ver figura 4.2.

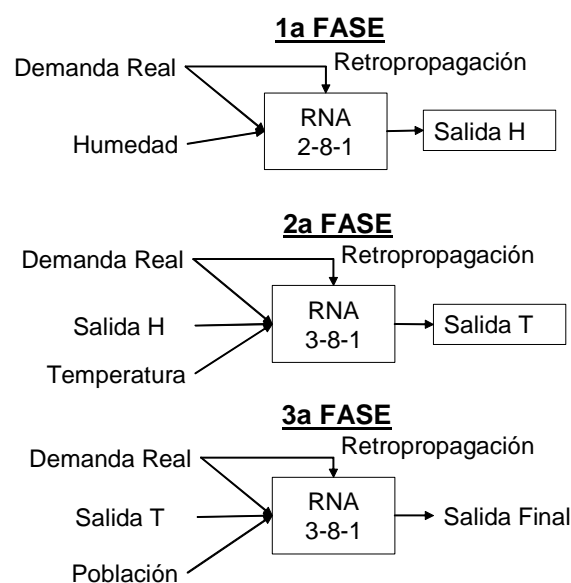


Figura 4.2. Esquema de la RNA En cascada.

Encontrando que para el método de regresión lineal y autorregresivo, se pudo constatar que su mejor ajuste se obtiene cuando se emplean todas las variables que se mencionan para cada caso; sin embargo, para el método de RNA, esta opción no fue la mejor.

### 4.3 Simulaciones

Para este trabajo se realizaron diferentes simulaciones para distintas regiones que representaban curvas de la demanda de energía eléctrica de diferente grado de complejidad, Para cada una de las regiones establecidas en este trabajo, se estandarizaron los datos con lo cual se llevaron a cabo las simulaciones indicadas.



### 4.3.1 Casos de simulación

Para este trabajo se utilizan, tres regiones eléctricas de la República Mexicana pertenecientes a CFE y una de Arabia las cuales presentan diferentes grados de complejidad, siendo estas las siguientes:

- ✓ **Región norte.-** Para este caso se refiere, a la muestra de los municipios de Chihuahua y CD. Juárez del estado de Chihuahua, considerando las variables climatológicas de la región y el crecimiento medio de la población de los últimos años y la demanda de energía registrada en esas ciudades. Los datos considerados comprenden de enero de 1990 a diciembre de 1993, los cuales se presentan en el “Anexo A”.
- ✓ **Región sur.-** Para la segunda simulación, se muestran los municipios de Coatzacoalcos, Minatitlan y Córdoba, del estado de Veracruz, considerando las variables climatológicas de la región y el crecimiento medio de la población de los últimos años y la demanda de energía registrada en esas ciudades. Los datos considerados comprenden de enero de 1990 a junio de 1995, los cuales se presentan en el “Anexo C”.
- ✓ **Región del Istmo.-** Como tercer caso de simulación, se muestran los datos de la región del Istmo de Tehuantepec del estado de Oaxaca, para el cual se emplearán las variables climatológicas de la región y el crecimiento medio de la población de los últimos años y la demanda de energía registrada en esa región. Los datos considerados comprenden de enero de 1987 a diciembre de 1989, los cuales se presentan en el “Anexo E”.
- ✓ **Región Arábiga de Dhaharán.-** Como ultimo caso de simulación, se muestran los datos de la región Arábiga de Dhaharán, para el cual se emplearán las variables climatológicas de la región y el crecimiento medio de la población de los últimos años y la demanda de energía registrada en esa ciudad. Los datos considerados comprenden de agosto de 1987 a julio de 1992, los cuales se presentan en el “Anexo G”.

### 4.3.2 Programas utilizados

Para cada uno de los métodos se desarrolló un programa en lenguaje FORTRAN\_90, para resolver el problema de pronóstico, el código de cada uno de los programas y los manuales para

la operación de cada programa se encuentran al final de este trabajo ver “Apéndice A,B,C,D,E, y F”.

#### 4.4 Región norte

Como ya se mencionó anteriormente, se muestran los datos de los municipios mencionados del estado de Chihuahua, considerando las variables climatológicas de la región y el crecimiento medio de la población de enero de 1990 a diciembre de 1993 y la demanda de energía registrada. Las gráficas que se muestran a continuación, representan cada una de las variables utilizadas.

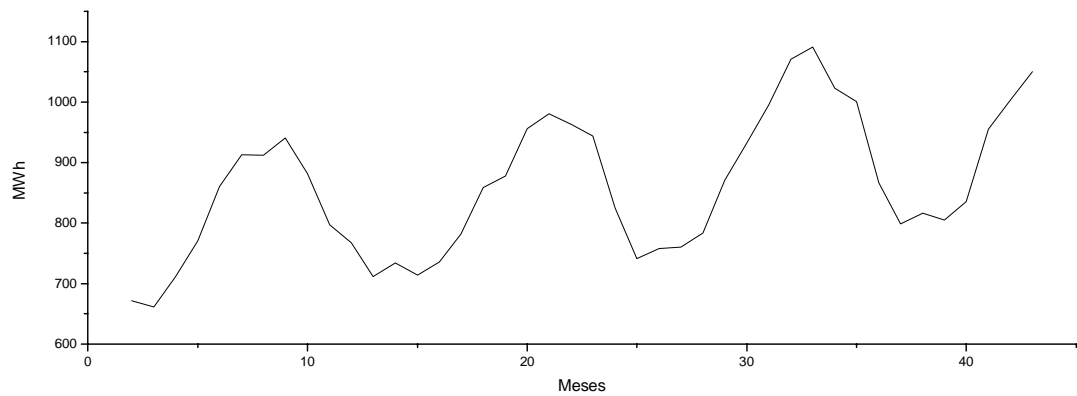


Figura 4.3. Gráfica de la demanda media mensual para la región norte.

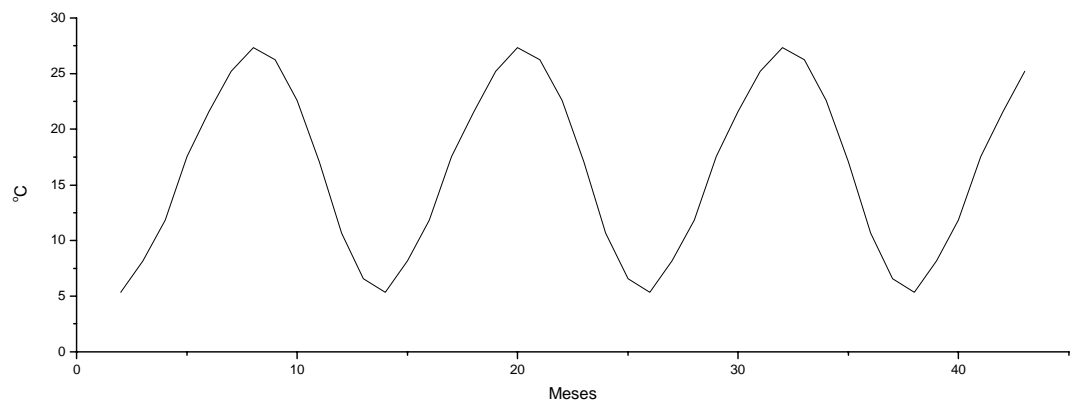


Figura 4.4. Gráfica de la temperatura media mensual, para la región norte.




Figura 4.5. Gráfica de la humedad media mensual, para la región norte.




Figura 4.6. Gráfica del Crecimiento medio de la población, para la región norte.

Como se mencionó anteriormente, cada variable se trató independientemente para obtener una estandarización que equipara la importancia de cada variable. Con lo que se mantuvieron las entradas y salidas dentro del rango dinámico de variación de la función de activación sigmoideal el cual esta dentro de  $[0,+1]$  ver “Anexo B” y en la Fig. 4.7.

Para este caso se presentan 48 meses que fueron analizados, de los cuales se utilizaron 42 para el entrenamiento de la red (Ajuste) y los seis restantes fueron considerados, solamente para comparar el resultado del pronóstico, estos últimos se encuentran dentro del área sombreada de la grafica que a continuación se presenta.

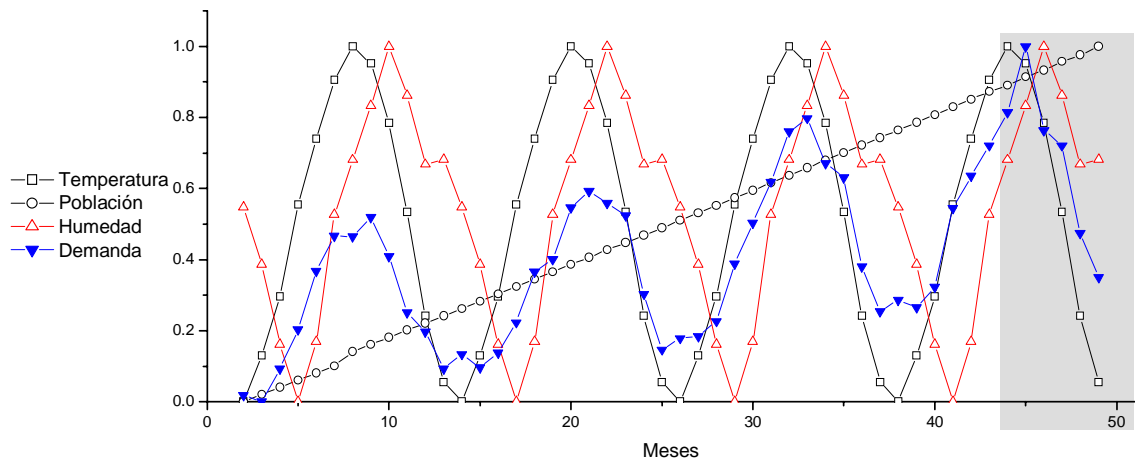


Figura 4.7. Gráfica de los datos estandarizados, para la región norte.

Tabla 4.1.- Niveles de correlación para la región norte.

Variable	Correlación con la Demanda.
Temperatura	0.78091406
Población	0.58791163
Humedad	0.41969564

Los niveles de correlación se presentan, ya que en éstos se muestra de qué manera influye cada variable con la demanda, lo cual ayuda en el análisis y selección de cada variable. Estos niveles sirven para determinar que las tres variables influyen favorablemente en el comportamiento de la demanda, es decir que las tres variables provocan de alguna manera el comportamiento de la demanda, lo cual se puede apreciar en la gráfica de la figura 4.7.

#### 4.4.1 Ajuste de datos de la región norte

A continuación se presentarán los resultados obtenidos con los programas desarrollados en lenguaje FORTRAN\_90, para cada método. Cabe mencionar que los resultados que se obtuvieron se dan en valores de P.U. para establecer los mismos rangos en cada simulación.

#### 4.4.1.1 Ajuste de datos con regresión lineal

En primer lugar, se presenta la gráfica de los resultados obtenidos con el programa desarrollado, para este caso durante el ajuste, contra los valores reales, representando el error encontrado en la parte inferior de la gráfica.

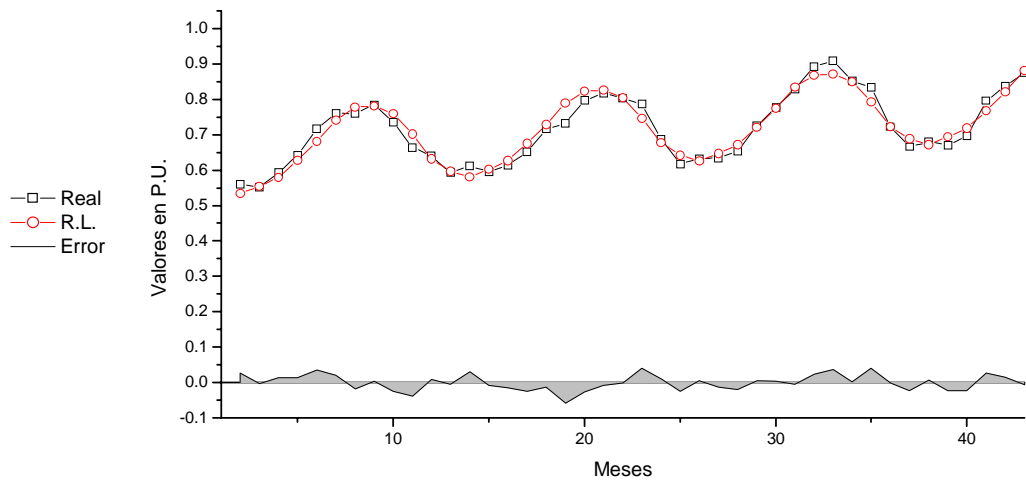


Figura 4.8. Gráfica del ajuste con regresión lineal para la región norte

Para reforzar la gráfica 4.8, se presentan en la tabla 4.2, los resultados que se obtuvieron durante el ajuste por el método de regresión lineal, estos valores se dan en P.U. con una base de 1200 MW, mostrándose el error para cada evento y su porcentaje que representa este error, con lo cual se calculan los errores absoluto acumulado de manera porcentual y el error medio absoluto.

Error total absoluto (en porcentaje)= 2.49

Error medio absoluto (P.U.)= 0.017

Tabla 4.2.- Ajuste de la curva mediante el método de Regresión lineal.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.56	0.5334	0.0267	4.76	22	0.7867	0.7467	0.04	5.08
2	0.5517	0.5544	-0.0027	-0.49	23	0.6875	0.6769	0.0106	1.54
3	0.5933	0.5795	0.0139	2.34	24	0.6175	0.6424	-0.0249	-4.03
4	0.6425	0.6276	0.0149	2.32	25	0.6317	0.6262	0.0055	0.86
5	0.7167	0.6804	0.0363	5.06	26	0.6342	0.6474	-0.0132	-2.09
6	0.7608	0.741	0.0198	2.60	27	0.6533	0.6727	-0.0194	-2.96
7	0.76	0.7779	-0.0179	-2.36	28	0.7258	0.721	0.0048	0.67
8	0.7842	0.7809	0.0033	0.42	29	0.7775	0.774	0.0035	0.45
9	0.735	0.7596	-0.0246	-3.34	30	0.8292	0.8348	-0.0056	-0.68
10	0.6642	0.7018	-0.0377	-5.67	31	0.8925	0.8682	0.0243	2.72
11	0.64	0.6319	0.0081	1.26	32	0.9092	0.8713	0.0378	4.16
12	0.5933	0.5973	-0.004	-0.67	33	0.8525	0.8502	0.0023	0.27
13	0.6117	0.5811	0.0306	5.00	34	0.8342	0.7926	0.0415	4.98
14	0.595	0.6022	-0.0072	-1.21	35	0.7225	0.7229	-0.0004	-0.06
15	0.6133	0.6274	-0.014	-2.29	36	0.6658	0.6885	-0.0227	-3.40
16	0.6517	0.6756	-0.0239	-3.67	37	0.68	0.6724	0.0076	1.11
17	0.7158	0.7285	-0.0126	-1.77	38	0.6708	0.6937	-0.0229	-3.41
18	0.7317	0.7892	-0.0575	-7.86	39	0.6967	0.7191	-0.0224	-3.22
19	0.7967	0.8225	-0.0258	-3.24	40	0.7958	0.7675	0.0284	3.56
20	0.8175	0.8256	-0.0081	-0.99	41	0.8367	0.8206	0.0161	1.92
21	0.8025	0.8043	-0.0018	-0.23	42	0.875	0.8815	-0.0065	-0.74

Los cálculos de los errores se realizaron en base a las formulas 2.1 y 2.2 del capítulo 2 (pag. 15).

#### 4.4.1.2 Ajuste de datos con VAR

A continuación se presentan en la tabla 4.3 los resultados obtenidos durante el ajuste de la curva con el programa desarrollado, para este método. Se muestran los resultados obtenidos contra los valores reales y el error encontrado, con estos resultados se calcularon los errores absoluto acumulado y el error medio absoluto, que se presentan a continuación.


Error total absoluto (en porciento)= 2.49

Error medio absoluto (P.U.)= 0.017

Tabla 4.3.- Valores obtenidos mediante el método de VAR.


	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.5600	0.5333	0.0267	4.76	22	0.7867	0.7467	0.0400	5.08
2	0.5517	0.5544	-0.0027	-0.49	23	0.6875	0.6769	0.0106	1.54
3	0.5933	0.5795	0.0139	2.34	24	0.6175	0.6424	-0.0249	-4.03
4	0.6425	0.6276	0.0149	2.32	25	0.6317	0.6262	0.0055	0.86
5	0.7167	0.6804	0.0363	5.06	26	0.6342	0.6474	-0.0132	-2.09
6	0.7608	0.7410	0.0198	2.60	27	0.6533	0.6727	-0.0193	-2.96
7	0.7600	0.7779	-0.0179	-2.36	28	0.7258	0.7210	0.0049	0.67
8	0.7842	0.7809	0.0033	0.42	29	0.7775	0.7740	0.0035	0.45
9	0.7350	0.7595	-0.0245	-3.34	30	0.8292	0.8348	-0.0056	-0.68
10	0.6642	0.7018	-0.0377	-5.67	31	0.8925	0.8682	0.0243	2.73
11	0.6400	0.6319	0.0081	1.26	32	0.9092	0.8713	0.0378	4.16
12	0.5933	0.5973	-0.0040	-0.67	33	0.8525	0.8502	0.0023	0.27
13	0.6117	0.5811	0.0306	5.00	34	0.8342	0.7926	0.0415	4.98
14	0.5950	0.6022	-0.0072	-1.21	35	0.7225	0.7229	-0.0004	-0.06
15	0.6133	0.6274	-0.0140	-2.29	36	0.6658	0.6885	-0.0227	-3.40
16	0.6517	0.6756	-0.0239	-3.67	37	0.6800	0.6724	0.0076	1.11
17	0.7158	0.7285	-0.0126	-1.77	38	0.6708	0.6937	-0.0229	-3.41
18	0.7317	0.7892	-0.0575	-7.86	39	0.6967	0.7191	-0.0224	-3.22
19	0.7967	0.8225	-0.0258	-3.24	40	0.7958	0.7675	0.0284	3.56
20	0.8175	0.8256	-0.0081	-0.99	41	0.8367	0.8206	0.0161	1.93
21	0.8025	0.8043	-0.0018	-0.23	42	0.8750	0.8815	-0.0065	-0.74

*Figura 4.9 Gráfica del ajuste y el pronóstico con VAR. para la región norte.*



#### 4.4.1.3 Simulación con RNA

En la figura 4.10 se muestra el ajuste alcanzado mediante este método. Presentándose estos resultados contra los valores reales, mostrando el error encontrado.



*Figura 4.10. Gráfica del ajuste con RNA, para la región norte.*

En la siguiente tabla se presentan los valores del ajuste que se obtuvieron mediante el método de RNA, mostrándose el error para cada evento.

Tabla 4.4.- Valores obtenidos mediante el método de RNA.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.5600	0.5899	-0.0299	-5.35	22	0.7867	0.7893	-0.0027	-0.34
2	0.5517	0.5871	-0.0354	-6.42	23	0.6875	0.6779	0.0096	1.39
3	0.5933	0.6066	-0.0133	-2.24	24	0.6175	0.6195	-0.0020	-0.33
4	0.6425	0.6404	0.0021	0.33	25	0.6317	0.6298	0.0019	0.30
5	0.7167	0.7120	0.0047	0.65	26	0.6342	0.6322	0.0019	0.31
6	0.7608	0.7610	-0.0001	-0.02	27	0.6533	0.6486	0.0048	0.73
7	0.7600	0.7591	0.0009	0.12	28	0.7258	0.7236	0.0023	0.31
8	0.7842	0.7866	-0.0024	-0.31	29	0.7775	0.7830	-0.0055	-0.71
9	0.7350	0.7283	0.0067	0.92	30	0.8292	0.8378	-0.0086	-1.04
10	0.6642	0.6550	0.0091	1.38	31	0.8925	0.8933	-0.0008	-0.09
11	0.6400	0.6356	0.0044	0.69	32	0.9092	0.9045	0.0047	0.51
12	0.5933	0.6052	-0.0119	-2.00	33	0.8525	0.8584	-0.0059	-0.69
13	0.6117	0.6162	-0.0045	-0.74	34	0.8342	0.8411	-0.0070	-0.83
14	0.5950	0.6069	-0.0119	-2.00	35	0.7225	0.7155	0.0070	0.97
15	0.6133	0.6186	-0.0052	-0.86	36	0.6658	0.6572	0.0087	1.30
16	0.6517	0.6480	0.0037	0.57	37	0.6800	0.6711	0.0089	1.31
17	0.7158	0.7111	0.0048	0.67	38	0.6708	0.6631	0.0077	1.15
18	0.7317	0.7268	0.0049	0.66	39	0.6967	0.6902	0.0065	0.93
19	0.7967	0.8017	-0.0050	-0.63	40	0.7958	0.8053	-0.0095	-1.19
20	0.8175	0.8239	-0.0064	-0.78	41	0.8367	0.8476	-0.0109	-1.30
21	0.8025	0.8067	-0.0042	-0.52	42	0.8750	0.8802	-0.0052	-0.60



Con los valores de esta tabla, se calcularon los errores absoluto acumulado, el error medio absoluto, los cuales se muestran a continuación.

Error total absoluto (en porciento)= 0.97

Error medio absoluto (P.U.)= 0.0069

#### 4.4.1.4 Resultados obtenidos durante el ajuste

A continuación se presenta una evaluación de los resultados obtenidos con los diferentes métodos indicados.

Tabla 4.5.- Evaluación de resultados para la región norte.

Caso	Error	
	Total Absoluto %	Medio Absoluto (P.U)
RNA	0.97	0.0069
R.L.	2.49	0.017
VAR.	2.49	0.017

Estas evaluaciones tienen el fin de dar criterios de desempeño del método, y obtener el mejor pronóstico. Así mismo se puede observar que el mejor de los ajustes fue el calculado mediante RNA.

#### 4.4.2 Pronóstico de la demanda para la región norte

A continuación, se presentarán los pronósticos logrados para los próximos 6 meses, con los programas desarrollados para cada método. Se muestran los valores de dicho pronóstico, los valores reales y el error encontrado; además se grafican dichos resultados a fin de visualizar los resultados, cabe mencionar que los pronósticos que se obtuvieron se dan en valores de P.U. para establecer los mismos rangos en cada simulación.

#### 4.4.2.1 Pronóstico con Regresión Lineal

A continuación se presentan los valores del pronóstico logrado por este método.




Figura 4.11 Gráfica del pronóstico con regresión lineal para la región norte.

Para reforzar la gráfica 4.11 se presentan en esta tabla los resultados del pronóstico que se obtuvieron por el método de regresión lineal, estos valores se dan en P.U. con una base de 1200 MW.

Tabla 4.6.- Pronóstico de la demanda mediante el método de Regresión lineal.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.9167	0.9142	0.0025	0.27
2	1	0.9179	0.0821	8.21
3	0.8942	0.8963	-0.0021	-0.24
4	0.875	0.8394	0.0357	4.07
5	0.7642	0.7691	-0.005	-0.65
6	0.7083	0.7353	-0.027	-3.81

El error absoluto acumulado y el error medio absoluto, se presentan a continuación.

$$\text{Error total absoluto (en porcentaje)} = 2.99$$

$$\text{Error medio absoluto (P.U.)} = 0.025$$

#### 4.4.2.2 Pronóstico con VAR

En la siguiente gráfica se presentan los valores del pronóstico logrado por este método.




Figura 4.12. Gráfica del pronóstico con VAR para la región norte.

A continuación se dan en la tabla 4.7 los resultados del pronóstico alcanzado con el programa desarrollado para este método.

Tabla 4.7.- Valores obtenidos mediante el método de VAR.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.9167	0.9142	0.0025	0.27
2	1.0000	0.9179	0.0821	8.21
3	0.8942	0.8963	-0.0021	-0.24
4	0.8750	0.8393	0.0357	4.08
5	0.7642	0.7691	-0.0050	-0.65
6	0.7083	0.7353	-0.0270	-3.81

Con estos resultados se calcularon el error absoluto acumulado y el error medio absoluto, que se presentan a continuación.

$$\text{Error total absoluto (en porcentaje)} = 2.99$$

$$\text{Error medio absoluto (P.U.)} = 0.025$$

### 4.4.2.3 Pronóstico con RNA

En la figura 4.13 se muestra el pronóstico obtenido con el programa desarrollado para resolver este problema mediante RNA.




Figura 4.13. Gráfica del pronóstico con RNA, para la región norte.

En la siguiente tabla, se presentan los valores del pronóstico alcanzado mediante el método de RNA, mostrándose el error para cada evento.

Tabla 4.8.- Valores obtenidos mediante el método de RNA.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.9167	0.9228	-0.0061	-0.67
2	1.0000	0.9310	0.0690	6.90
3	0.8942	0.8964	-0.0022	-0.25
4	0.8750	0.8828	-0.0078	-0.90
5	0.7642	0.7689	-0.0048	-0.62
6	0.7083	0.7033	0.0050	0.71

Con los valores del pronóstico, se calcularon los errores absoluto acumulado, el error medio absoluto los que se muestran a continuación.

$$\text{Error Total absoluto (en porciento)} = 1.84$$

$$\text{Error Medio absoluto (P.U.)} = 0.015$$

#### 4.4.2.4 Resultados obtenidos

En la siguiente tabla, se presenta una evaluación de los pronósticos obtenidos con los métodos indicados, estas evaluaciones tienen el fin de dar criterios de desempeño para su uso, así mismo se puede observar que el mejor de los pronósticos, fue el calculado mediante RNA:

Tabla 4.9.- Resultados obtenidos para la región norte.

Caso	Error	
	Total Absoluto %	Medio Absoluto (P.U.)
RNA	1.84	0.015
R.L.	2.99	0.025
VAR.	2.99	0.025

#### 4.4.3 Comparación de resultados

A continuación, se comparan los resultados logrados con el método de regresión lineal contra el de RNA, con lo cual se puede decir que el pronóstico más próximo a la realidad, es el que se había indicado durante el ajuste, siendo éste el logrado con la red neuronal alimentada en forma de cascada, de tres capas con 3 neuronas en la capa de entrada 8 en la oculta y una en la capa de salida, en la siguiente figura se muestra una comparación gráfica entre el método de RNA y R.L.




Figura 4.14. Gráfica comparativa del ajuste del método de R.L. contra RNA




Figura 4.15. Gráfica comparativa del pronóstico del método de R.L. contra RNA

En las gráficas de las figuras 4.14 y 4.15, se puede observar que el método de redes neuronales, puede pronosticar con mayor precisión la demanda de energía eléctrica, ya que los errores que presenta son menores que con los otros métodos, tanto para el ajuste como para el pronóstico, el desempeño del método de RNA resulta ser el que da solución al problema del pronóstico con mayor exactitud.

#### 4.5 Región sur

Para este caso, se muestran tres municipios del estado de Veracruz, considerando las variables climatológicas de la región y el crecimiento medio de la población y la demanda de energía registrada de enero de 1990 a junio de 1995, los cuales se presentan en el “Anexo F” y en las siguientes figuras:




Figura 4.16. Gráfica de la demanda media mensual, para la región sur.




Figura 4.17. Gráfica de la temperatura media mensual, para la región sur.

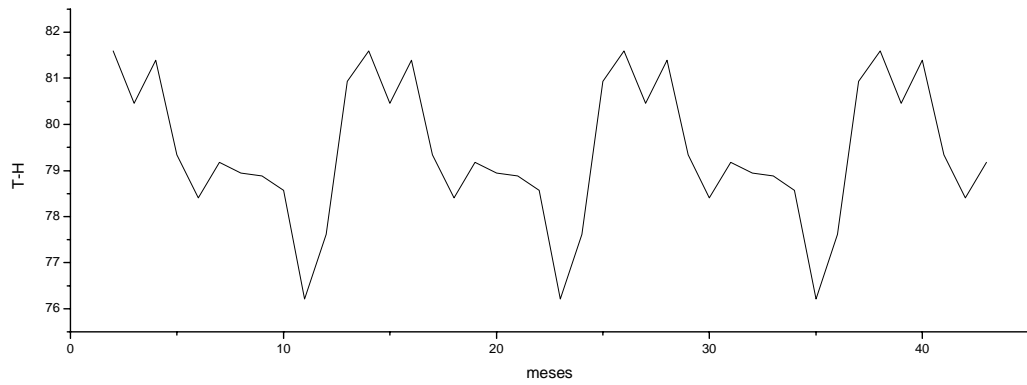


Figura 4.18. Gráfica de la humedad media mensual, para la región sur.




Figura 4.19. Gráfica del crecimiento de la población, para la región sur.

Como en el ejemplo anterior, cada variable se trató independientemente para obtener una estandarización dentro de  $[0,+1]$ , como a continuación se muestra ver “Anexo G”.

Para este caso, se presentan 48 meses que fueron analizados, de los cuales se utilizaron 42 para el entrenamiento de la red y los seis últimos datos no fueron considerados, solamente se emplearon para comparar el resultado del pronóstico obtenido, estos valores se encuentran con el área sombreada en la figura 4.20.




Figura 4.20. Gráfica de los datos estandarizados, para la región sur.

Tabla 4.10.- Niveles de correlación para la región sur.

Variable	Correlación con la Demanda.
Temperatura	0.2167
Población	0.9156
Humedad	-0.2840

En los niveles de correlación que se presentaron, se puede observar que no todas las variables influyen considerablemente con la demanda, lo cual ayuda en el análisis y selección de cada variable, lo que nos lleva a decir que la variable que más influye en la demanda es el crecimiento de la población, lo anterior se puede apreciar en la gráfica de la figura 4.20.

#### 4.5.1 Ajuste de datos de la región sur

En los siguientes puntos, se presentan los resultados obtenidos en el ajuste por los diferentes métodos, en éstos se muestran los valores obtenidos y se calculan los errores de los ajustes para presentar un avaluación de estos resultados.



### 4.5.1.1 Ajuste de datos con Regresión Lineal

A continuación, se presenta la gráfica de los resultados obtenidos mediante el método de regresión lineal, en ésta se puede observar el error en la parte inferior de la gráfica:




Figura 4.21 Gráfica del ajuste con regresión lineal para la región sur.

Tabla 4.11.- Valores del ajuste alcanzado mediante el método de regresión lineal.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.7153	0.6823	0.0330	4.62	22	0.7921	0.8140	-0.0219	-2.76
2	0.6980	0.6948	0.0032	0.46	23	0.7946	0.8045	-0.0100	-1.26
3	0.6683	0.7052	-0.0369	-5.52	24	0.7946	0.7836	0.0109	1.37
4	0.7327	0.7270	0.0057	0.78	25	0.7871	0.7843	0.0028	0.36
5	0.7277	0.7403	-0.0126	-1.73	26	0.7723	0.7969	-0.0246	-3.19
6	0.7673	0.7371	0.0303	3.94	27	0.7748	0.8074	-0.0326	-4.21
7	0.7376	0.7416	-0.0040	-0.54	28	0.8267	0.8293	-0.0025	-0.31
8	0.7277	0.7470	-0.0193	-2.65	29	0.8589	0.8428	0.0161	1.88
9	0.7252	0.7521	-0.0268	-3.70	30	0.8738	0.8396	0.0341	3.91
10	0.7649	0.7628	0.0020	0.27	31	0.8960	0.8443	0.0518	5.78
11	0.7550	0.7533	0.0016	0.22	32	0.8465	0.8498	-0.0033	-0.38
12	0.7426	0.7324	0.0102	1.37	33	0.8787	0.8550	0.0237	2.70
13	0.7525	0.7329	0.0195	2.60	34	0.8342	0.8658	-0.0317	-3.80
14	0.7599	0.7455	0.0144	1.90	35	0.8589	0.8565	0.0024	0.28
15	0.7252	0.7559	-0.0307	-4.23	36	0.8465	0.8356	0.0109	1.29
16	0.7599	0.7778	-0.0179	-2.35	37	0.8317	0.8363	-0.0046	-0.56
17	0.7995	0.7912	0.0083	1.04	38	0.8391	0.8490	-0.0099	-1.18
18	0.7871	0.7880	-0.0009	-0.11	39	0.8317	0.8595	-0.0279	-3.35
19	0.8069	0.7926	0.0144	1.78	40	0.8639	0.8815	-0.0177	-2.04
20	0.8045	0.7980	0.0064	0.80	41	0.9010	0.8951	0.0059	0.66
21	0.8168	0.8032	0.0137	1.67	42	0.9059	0.8920	0.0140	1.54

En esta tabla, se presentan los resultados del ajuste, contra los valores reales y el error encontrado, con estos valores se calcularon el error absoluto acumulado y el error medio absoluto que se presentan a continuación.

Error total absoluto (en porciento)= 2.01

Error medio absoluto (P.U.)= 0.0159

#### 4.5.1.2 Ajuste de datos con VAR

A continuación se presenta el ajuste logrado con este método. Presentando la siguiente tabla con dichos resultados, valores reales y el error encontrado para cada evento.

Tabla 4.12.- Valores del ajuste alcanzado mediante VAR.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.7153	0.6836	0.0317	4.43	22	0.7921	0.8153	-0.0232	-2.93
2	0.6980	0.6961	0.0019	0.27	23	0.7946	0.8059	-0.0113	-1.43
3	0.6683	0.7065	-0.0382	-5.71	24	0.7946	0.7850	0.0096	1.20
4	0.7327	0.7283	0.0044	0.60	25	0.7871	0.7856	0.0015	0.19
5	0.7277	0.7417	-0.0139	-1.91	26	0.7723	0.7982	-0.0259	-3.36
6	0.7673	0.7384	0.0289	3.77	27	0.7748	0.8087	-0.0340	-4.38
7	0.7376	0.7429	-0.0053	-0.72	28	0.8267	0.8306	-0.0039	-0.47
8	0.7277	0.7483	-0.0206	-2.83	29	0.8589	0.8441	0.0148	1.72
9	0.7252	0.7534	-0.0281	-3.88	30	0.8738	0.8410	0.0328	3.75
10	0.7649	0.7641	0.0007	0.09	31	0.8960	0.8456	0.0504	5.63
11	0.7550	0.7547	0.0003	0.04	32	0.8465	0.8511	-0.0046	-0.54
12	0.7426	0.7337	0.0089	1.20	33	0.8787	0.8563	0.0224	2.55
13	0.7525	0.7343	0.0182	2.42	34	0.8342	0.8672	-0.0330	-3.96
14	0.7599	0.7468	0.0131	1.72	35	0.8589	0.8578	0.0011	0.13
15	0.7252	0.7573	-0.0320	-4.41	36	0.8465	0.8370	0.0096	1.13
16	0.7599	0.7791	-0.0192	-2.53	37	0.8317	0.8377	-0.0060	-0.72
17	0.7995	0.7925	0.0070	0.87	38	0.8391	0.8503	-0.0112	-1.34
18	0.7871	0.7893	-0.0022	-0.28	39	0.8317	0.8609	-0.0292	-3.51
19	0.8069	0.7939	0.0130	1.62	40	0.8639	0.8829	-0.0190	-2.20
20	0.8045	0.7994	0.0051	0.63	41	0.9010	0.8964	0.0046	0.51
21	0.8168	0.8045	0.0123	1.51	42	0.9059	0.8933	0.0126	1.39

Con los resultados que se obtuvieron, se calcularon los errores absoluto acumulado y medio absoluto.

Error total absoluto (en porciento)= 1.99

Error medio absoluto (P.U.)= 0.0158

A continuación se presenta la gráfica 4.22, con el ajuste obtenido mediante este método y en la cual se pueden visualizar los errores encontrados para este método.




Figura 4.22 Gráfica del ajuste alcanzado con VAR para la región sur.

#### 4.5.1.3 Ajuste de datos con RNA

A continuación se presenta la gráfica y los valores de los resultados que se alcanzaron durante el ajuste por medio de este método.




Figura 4.23 Gráfica del ajuste mediante RNA utilizando la temperatura, para la región sur.

Tabla 4.13.- Valores del ajuste alcanzado mediante RNA.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.7153	0.7196	-0.0043	-0.60	22	0.7921	0.7905	0.0016	0.20
2	0.6980	0.7088	-0.0108	-1.55	23	0.7946	0.7930	0.0016	0.20
3	0.6683	0.6948	-0.0265	-3.97	24	0.7946	0.7927	0.0018	0.23
4	0.7327	0.7328	-0.0002	-0.02	25	0.7871	0.7847	0.0024	0.31
5	0.7277	0.7290	-0.0012	-0.17	26	0.7723	0.7692	0.0031	0.40
6	0.7673	0.7645	0.0028	0.37	27	0.7748	0.7720	0.0028	0.36
7	0.7376	0.7369	0.0007	0.10	28	0.8267	0.8281	-0.0014	-0.17
8	0.7277	0.7289	-0.0012	-0.17	29	0.8589	0.8605	-0.0016	-0.19
9	0.7252	0.7270	-0.0018	-0.25	30	0.8738	0.8738	-0.0001	-0.01
10	0.7649	0.7620	0.0029	0.38	31	0.8960	0.8917	0.0044	0.49
11	0.7550	0.7522	0.0027	0.36	32	0.8465	0.8485	-0.0020	-0.24
12	0.7426	0.7408	0.0018	0.24	33	0.8787	0.8780	0.0007	0.08
13	0.7525	0.7497	0.0028	0.37	34	0.8342	0.8358	-0.0017	-0.20
14	0.7599	0.7568	0.0031	0.41	35	0.8589	0.8603	-0.0013	-0.16
15	0.7252	0.7270	-0.0017	-0.24	36	0.8465	0.8480	-0.0015	-0.17
16	0.7599	0.7572	0.0027	0.36	37	0.8317	0.8328	-0.0011	-0.13
17	0.7995	0.7987	0.0009	0.11	38	0.8391	0.8406	-0.0015	-0.18
18	0.7871	0.7852	0.0019	0.24	39	0.8317	0.8332	-0.0015	-0.18
19	0.8069	0.8067	0.0002	0.03	40	0.8639	0.8651	-0.0012	-0.14
20	0.8045	0.8040	0.0004	0.05	41	0.9010	0.8953	0.0057	0.63
21	0.8168	0.8175	-0.0007	-0.08	42	0.9059	0.8987	0.0072	0.80

Con los valores presentados en esta tabla se calculan, el error absoluto acumulado y el error medio absoluto, los cuales se presentan a continuación.

$$\text{Error total absoluto (en porciento)} = 0.35$$

$$\text{Error medio absoluto (P.U.)} = 0.0027$$

#### 4.5.1.4 Resultados obtenidos durante el ajuste

De las diferentes simulaciones realizadas para este ejemplo, se obtuvieron los siguientes resultados, los cuales se muestran en la siguiente tabla:

Tabla 4.14.- Resultados obtenidos para la región sur durante el ajuste.

Caso	Error	
	Total absoluto %	Medio absoluto (P.U.)
RNA	0.35	0.0027
R.L.	2.01	0.0159
VAR.	1.99	0.0158

En la tabla anterior, se presentaron distintas evaluaciones del error encontrado para cada método analizado, con estas evaluaciones se puede observar que el mejor de los pronósticos fue el obtenido mediante RNA.

#### 4.5.2 Pronóstico de la demanda en la región sur

A continuación se presentarán los pronósticos alcanzados para los próximos 6 meses, con los métodos empleados. Presentándose los valores de dicho pronóstico, los valores reales y el error encontrado, además se grafican dichos resultados a fin de visualizar los pronósticos encontrados.

##### 4.5.2.1 Pronóstico con Regresión Lineal

Primeramente se presentan en la figura 4.24 los valores del pronóstico logrado por este método.




Figura 4.24 Gráfica de pronósticos con regresión lineal para la región sur.

En la siguiente tabla se presentan los resultados del pronóstico que se obtuvieron por regresión lineal, dados en P.U. con una base de 404 MW.

Tabla 4.15.- Pronóstico de la demanda alcanzado mediante el método de Regresión lineal.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	1.0000	0.8967	0.1033	10.33
2	0.8960	0.9023	-0.0062	-0.69
3	0.9480	0.9075	0.0405	4.27
4	0.8837	0.9184	-0.0348	-3.94
5	0.9356	0.9091	0.0265	2.83
6	0.9109	0.8884	0.0225	2.47

El error absoluto acumulado y el error medio absoluto, se presentan a continuación.

$$\text{Error total absoluto (en por ciento)} = 4.19$$

$$\text{Error medio absoluto (P.U.)} = 0.0389$$

#### 4.5.2.2 Pronóstico con VAR

En la gráfica 4.25 se presentan los valores del pronóstico logrado por este método.




Figura 4.25 Gráfica del pronóstico con VAR para la región sur.

A continuación se presentan en la tabla 4.16, los resultados del pronóstico alcanzado por este método.

Tabla 4.16.- Valores obtenidos mediante el método de VAR.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	1.0000	0.8980	0.1020	10.20
2	0.8960	0.9036	-0.0076	-0.84
3	0.9480	0.9089	0.0392	4.13
4	0.8837	0.9198	-0.0361	-4.09
5	0.9356	0.9105	0.0252	2.69
6	0.9109	0.8897	0.0212	2.33

Con estos resultados se calcularon los errores absoluto acumulado y el error medio absoluto, que se presentan a continuación.

$$\text{Error total absoluto (en porciento)} = 4.14$$

$$\text{Error medio absoluto (P.U.)} = 0.0385$$

#### 4.5.2.3 Pronóstico con RNA

En la figura 4.26 se presentan los resultados del pronóstico logrado con el programa desarrollado para resolver este problema mediante RNA.




Figura 4.26. Gráfica del pronóstico alcanzado con RNA, para la región sur.

En la siguiente tabla se presentan los valores del pronóstico logrado mediante el método de RNA, mostrándose el error para cada evento.

Tabla 4.17.- Valores obtenidos mediante el método de RNA.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	1.0000	0.9276	0.0724	7.24
2	0.8960	0.9004	-0.0043	-0.48
3	0.9480	0.9194	0.0287	3.02
4	0.8837	0.8916	-0.0079	-0.90
5	0.9356	0.9081	0.0275	2.94
6	0.9109	0.8999	0.0110	1.20

Los errores absoluto acumulado y el error medio absoluto son mostrados a continuación.

$$\text{Error Total absoluto (en porciento)}= 2.72$$

$$\text{Error Medio absoluto (P.U.)}= 0.0253$$

#### 4.5.2.4 Resultados obtenidos

A continuación se presentan las evaluaciones de los pronósticos obtenidos con los distintos métodos con el fin de dar criterios de desempeño para su uso, así mismo se puede observar que el mejor de los pronósticos fue el calculado mediante RNA:


Tabla 4.18.- Evaluación de los pronósticos alcanzados por los distintos métodos.

Caso	Error	
	Total Absoluto %	Medio Absoluto (P.U.)
RNA	2.72	0.0253
R.L.	4.19	0.0389
VAR.	4.14	0.0385


#### 4.5.3 Comparación de resultados

A continuación se comparan los resultados logrados con el método de VAR y el de RNA, con lo cual, se puede decir que el pronóstico más próximo a la realidad, es el que se había indicado durante el ajuste, siendo éste el logrado con la red neuronal, alimentada con la temperatura y la demanda de energía, de tres capas con 2 neuronas en la capa de entrada 8 en la oculta y una en la capa de salida, en la siguiente figura se muestra una comparación gráfica entre dichos métodos.





*Figura 4.27. Gráfica comparativa del ajuste del método de VAR. contra RNA.*



*Figura 4.28. Gráfica comparativa del pronóstico del método de VAR. contra RNA.*

En las gráficas de las figuras 4.27 y 4.28 se observa que el método de redes neuronales logró pronosticar con mayor precisión la demanda de energía eléctrica, en virtud de que los errores que se presentan son menores que con los otros métodos, por lo tanto, el desempeño del método de RNA resulta ser el que da mejor solución al problema del pronóstico para esta región.

## 4.6 Región Istmo

Para el tercer caso de simulación, se emplearon los datos de la región del Istmo de Tehuantepec del estado de Oaxaca, donde se emplearan las variables climatológicas de la región y el crecimiento medio de la población y la demanda de energía eléctrica registrada en esa región de enero de 1987 a diciembre de 1989. Los cuales se presentan a continuación; ver “Anexo E”.




Figura 4.29. Gráfica de la demanda media mensual, de la región Istmo.




Figura 4.30 Gráfica de la temperatura media, de la región Istmo.




Figura 4.31 Gráfica de la humedad media, de la región Istmo.




Figura 4.32 Gráfica del crecimiento poblacional, de la región Istmo.

Como se ha venido haciendo cada variable, se trató independientemente para obtener una estandarización dentro de  $[0,+1]$ , ver “Anexo L”.

Para este caso se presentan 36 meses que fueron analizados, de los cuales se utilizaron 30 para el entrenamiento de la red (Ajuste) y los seis restantes no fueron considerados, solamente se emplean para comparar el resultado del pronóstico obtenido.




Figura 4.33. Gráfica de los datos estandarizados, de la región Istmo.

Tabla 4.19.- Niveles de correlación para la región Istmo

Variable	Correlación con la Demanda.
Temperatura	0.6846
Población	0.1001
Humedad	-0.4483


En los niveles de correlación que se presentan, se puede observar que la temperatura es la variable que más influye o interactúa con la demanda y así mismo la población es la que menos influye, esto ayuda en el análisis y selección de cada variable, lo anterior se puede apreciar en la gráfica de la figura 4.33.

#### 4.6.1 Ajuste de datos de la región Istmo

Como se ha venido realizando en los ejemplos anteriores, se presentarán a continuación en los siguientes puntos los resultados que se han logrado durante el ajuste para la región Istmo mediante los métodos que en este trabajo se analizaron.

##### 4.6.1.1 Ajuste de datos con regresión lineal

A continuación se presentan los resultados del ajuste alcanzado mediante el método de regresión lineal, presentando los resultados obtenidos, el valor real y el error para cada evento.



*Figura 4.34 Gráfica del ajuste con regresión lineal para el Istmo.*

Tabla 4.20.- Valores obtenidos mediante regresión lineal.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.6000	0.6077	-0.0077	-1.28	16	0.6480	0.7988	-0.1508	-23.27
2	0.5920	0.6432	-0.0512	-8.64	17	0.7080	0.8491	-0.1411	-19.92
3	0.6200	0.7309	-0.1109	-17.88	18	0.7600	0.8050	-0.0450	-5.92
4	0.8400	0.8206	0.0194	2.31	19	0.9200	0.7976	0.1224	13.31
5	0.9600	0.8709	0.0891	9.28	20	0.9600	0.8046	0.1554	16.18
6	0.9800	0.8269	0.1531	15.62	21	0.9200	0.7999	0.1201	13.06
7	1.0000	0.8195	0.1805	18.05	22	0.8000	0.7765	0.0235	2.93
8	0.8800	0.8266	0.0534	6.07	23	0.7000	0.6962	0.0038	0.54
9	0.7600	0.8219	-0.0619	-8.14	24	0.6400	0.5765	0.0635	9.93
10	0.6800	0.7986	-0.1186	-17.44	25	0.6400	0.5638	0.0762	11.91
11	0.5800	0.7183	-0.1383	-23.85	26	0.6800	0.5992	0.0808	11.88
12	0.6200	0.5986	0.0214	3.45	27	0.5920	0.6868	-0.0948	-16.02
13	0.6400	0.5860	0.0540	8.44	28	0.6000	0.7765	-0.1765	-29.42
14	0.6200	0.6214	-0.0014	-0.23	29	0.8400	0.8267	0.0133	1.58
15	0.5600	0.7091	-0.1491	-26.62	30	0.8000	0.7827	0.0173	2.17

En esta tabla, se presentan los valores del ajuste obtenidos mediante este método, donde se muestra el error para cada evento con lo cual se calcularon los errores absoluto acumulado y el error medio absoluto, los cuales se presentan a continuación.

Error Total absoluto (en porciento)= 11.26

Error Medio absoluto (P.U.)= 0.0831

### 4.6.1.2 Ajuste de datos con VAR

A continuación se presentan los resultados del ajuste obtenido con este método, presentando en la siguiente tabla estos resultados, los valores reales y el error encontrado para cada evento.


Tabla 4.21.- Valores obtenidos mediante VAR.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.6	0.5831	0.0169	2.82	16	0.648	0.7992	-0.1512	-23.34
2	0.592	0.6196	-0.0276	-4.67	17	0.708	0.8506	-0.1426	-20.14
3	0.62	0.7092	-0.0892	-14.38	18	0.76	0.8090	-0.0490	-6.45
4	0.84	0.7992	0.0408	4.85	19	0.92	0.8033	0.1167	12.68
5	0.96	0.8506	0.1094	11.39	20	0.96	0.8122	0.1478	15.40
6	0.98	0.8090	0.1710	17.44	21	0.92	0.8091	0.1109	12.06
7	1	0.8033	0.1967	19.67	22	0.8	0.7866	0.0134	1.68
8	0.88	0.8122	0.0678	7.71	23	0.7	0.7092	-0.0092	-1.31
9	0.76	0.8091	-0.0491	-6.46	24	0.64	0.5935	0.0465	7.26
10	0.68	0.7866	-0.1066	-15.67	25	0.64	0.5831	0.0569	8.89
11	0.58	0.7092	-0.1292	-22.27	26	0.68	0.6196	0.0604	8.88
12	0.62	0.5935	0.0265	4.27	27	0.592	0.7092	-0.1172	-19.79
13	0.64	0.5831	0.0569	8.89	28	0.6	0.7992	-0.1992	-33.20
14	0.62	0.6196	0.0004	0.06	29	0.84	0.8506	-0.0106	-1.26
15	0.56	0.7092	-0.1492	-26.64	30	0.8	0.8090	-0.0090	-1.13

Con los resultados obtenidos se calcularon los errores absoluto acumulado y el error medio absoluto.

Error Total absoluto (en porcentaje)= 11.19


Error Medio absoluto (P.U.)= 0.0825



*Figura 4.35 Gráfica del ajuste obtenido con VAR. Para el Istmo.*

### 4.6.1.3 Ajuste de datos con RNA

A continuación se muestra la gráfica 4.36 en la cual se presenta el ajuste logrado mediante el método de RNA en dicha gráfica se puede apreciar el ajuste, los valores reales y el error del citado ajuste.



*Figura 4.36 Gráfica del ajuste utilizando RNA, para el Istmo.*

Continuando con este caso, se presenta la siguiente tabla con los resultados del ajuste alcanzado por este método.

Tabla 4.22.- Valores obtenidos mediante RNA.

	Demanda PU	Valor Obtenido PU	Error	Error %		Demanda PU	Valor Obtenido PU	Error	Error %
1	0.6	0.6150	-0.0150	-2.50	16	0.648	0.6441	0.0039	0.61
2	0.592	0.6107	-0.0187	-3.16	17	0.708	0.6977	0.0103	1.45
3	0.62	0.6255	-0.0055	-0.89	18	0.76	0.7570	0.0030	0.39
4	0.84	0.8499	-0.0099	-1.17	19	0.92	0.9198	0.0002	0.02
5	0.96	0.9430	0.0170	1.77	20	0.96	0.9433	0.0167	1.74
6	0.98	0.9525	0.0275	2.80	21	0.92	0.9198	0.0002	0.02
7	1	0.9604	0.0396	3.96	22	0.8	0.8055	-0.0055	-0.69
8	0.88	0.8886	-0.0086	-0.98	23	0.7	0.6915	0.0085	1.21
9	0.76	0.7571	0.0029	0.38	24	0.64	0.6400	0.0000	0.00
10	0.68	0.6713	0.0087	1.28	25	0.64	0.6400	0.0000	0.00
11	0.58	0.6047	-0.0247	-4.25	26	0.68	0.6728	0.0072	1.05
12	0.62	0.6265	-0.0065	-1.05	27	0.592	0.6101	-0.0181	-3.05
13	0.64	0.6400	0.0000	0.00	28	0.6	0.6136	-0.0136	-2.27
14	0.62	0.6263	-0.0063	-1.02	29	0.84	0.8492	-0.0092	-1.10
15	0.56	0.5964	-0.0364	-6.50	30	0.8	0.8047	-0.0047	-0.59

Con los valores presentados en esta tabla, se calcularon los errores absoluto acumulado y el error medio absoluto, los cuales se presentan a continuación.

$$\begin{aligned} \text{Error Total absoluto (en porciento)} &= 1.48 \\ \text{Error Medio absoluto (P.U.)} &= 0.0109 \end{aligned}$$

#### 4.6.1.4 Resultados obtenidos

De las distintas simulaciones realizadas, se presentan los resultados obtenidos, indicando el error total absoluto dado de manera porcentual, el error medio absoluto:

Tabla 4.23.- Resultados obtenidos durante el ajuste, para la región del Istmo.

Caso	Error	
	Total absoluto %	Medio absoluto (P.U.)
RNA	1.48	0.0109
R.L.	11.26	0.0831
VAR.	11.19	0.0825

En la tabla anterior, se presentaron distintas evaluaciones del error encontrado por cada método analizado, con estas evaluaciones se puede observar que el mejor de los ajustes fue el obtenido mediante RNA.

#### 4.6.2 Pronóstico de la demanda en la región del Istmo

Como en los ejemplos anteriores, se presentará el pronóstico alcanzado para los próximos 6 meses en esta región. Se muestran los valores de dicho pronóstico, los valores reales y los errores encontrados, además de graficar dichos resultados, cabe mencionar que los pronósticos que se obtuvieron se dan en valores de P.U. para establecer los mismos rangos en cada simulación, con una base de 2500 MW.



### 4.6.2.1 Pronóstico con Regresión Lineal

A continuación se presentan los valores del pronóstico alcanzado por este método.




Figura 4.37. Gráfica del pronóstico con regresión lineal para el Istmo.

Para reforzar esta gráfica, se presentan a continuación la tabla con los resultados del pronóstico alcanzado por este método.

Tabla 4.24.- Pronóstico de la demanda alcanzado mediante el método de regresión lineal.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.9400	0.8209	0.1191	12.67
2	0.9600	0.8317	0.1283	13.37
3	0.9400	0.8306	0.1094	11.63
4	0.7600	0.8111	-0.0511	-6.72
5	0.7600	0.7345	0.0255	3.36
6	0.6600	0.6185	0.0415	6.29

El error absoluto acumulado y el error medio absoluto se presentan a continuación:

$$\text{Error total absoluto (en porciento)} = 9.45$$

$$\text{Error medio absoluto (P.U.)} = 0.0791$$

#### 4.6.2.2 Pronóstico con VAR

En la siguiente gráfica, se presentan los resultados del pronóstico logrado por este método.




Figura 4.38. Gráfica del pronóstico con VAR para la región Istmo.

A continuación se dan en la tabla 4.25 los resultados del pronóstico logrado con este método.

Tabla 4.25.- valores obtenidos mediante el método de VAR.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.94	0.8033	0.1367	14.54
2	0.96	0.8122	0.1478	15.40
3	0.94	0.8091	0.1309	13.93
4	0.76	0.7866	-0.0266	-3.49
5	0.76	0.7092	0.0508	6.69
6	0.66	0.5935	0.0665	10.07

A continuación se presentan los errores absoluto acumulado y el error medio absoluto:

Error total absoluto (en porciento)= 11.14

Error medio absoluto (P.U.)= 0.0932

### 4.6.2.3 Pronóstico con RNA

En la figura 4.39 se muestra el pronóstico alcanzado con el programa desarrollado para resolver este problema mediante RNA.




Figura 4.39. Gráfica del pronóstico con RNA, para la región Istmo.

En la siguiente tabla, se presentan los valores del pronóstico logrado mediante el método de RNA, mostrándose el error para cada evento.

Tabla 4.26.- Valores del pronóstico obtenido mediante el método de RNA.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.94	0.9198	0.0202	2.15
2	0.96	0.9433	0.0167	1.74
3	0.94	0.9198	0.0202	2.15
4	0.76	0.8055	-0.0455	-5.99
5	0.76	0.6915	0.0685	9.01
6	0.66	0.6400	0.0200	3.03

Con estos valores se calcularon los errores absoluto acumulado, el error medio absoluto los que se muestran a continuación.

$$\text{Error Total absoluto (en porciento)} = 3.80$$

$$\text{Error Medio absoluto (P.U.)} = 0.0318$$

#### 4.6.2.4 Resultados obtenidos

En la siguiente tabla, se presenta una evaluación de los pronósticos obtenidos, estas evaluaciones tienen el fin de dar criterios de desempeño del pronóstico para su uso, así mismo se puede observar que el mejor de los pronósticos fue el logrado mediante RNA:

Tabla 4.27.- Evaluación de los pronóstico alcanzados para el Istmo

Caso	Error	
	Total Absoluto %	Medio Absoluto (P.U.)
RNA	3.80	0.0318
R.L.	9.45	0.0791
VAR.	11.14	0.0932

#### 4.6.3 Comparación de resultados

A continuación se comparan los resultados alcanzados con el método de regresión lineal contra el de RNA, con lo cual se puede decir que el pronóstico mas próximo a la realidad, es el que se había indicado desde el ajuste, siendo la red neuronal de tres capas que se alimento con la demanda real y la temperatura esta red cuenta con dos neuronas en la capa de entrada siete en la capa oculta y una en la capa de salida, las siguientes gráficas muestran la comparación entre dichos métodos.




Figura 4.40. Gráfica comparativa del ajuste del método de R.L. contra RNA

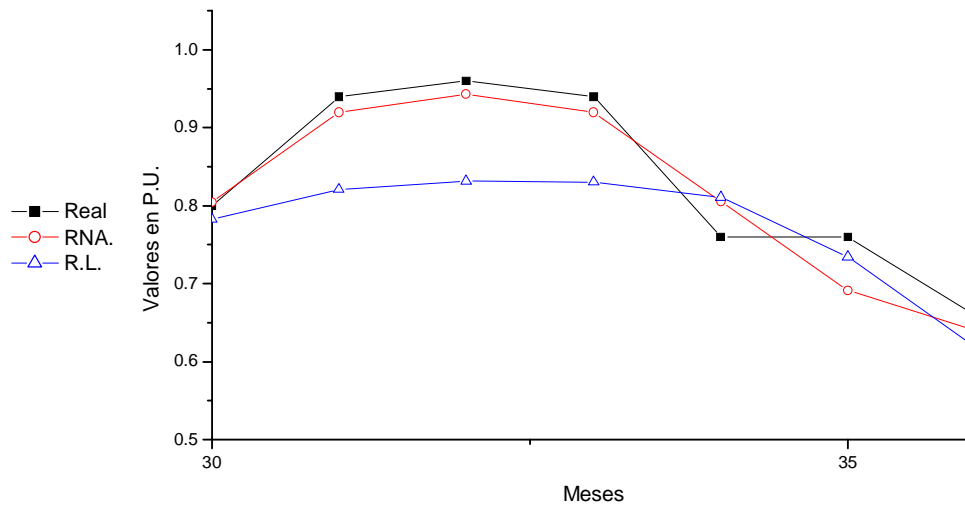


Figura 4.41. Gráfica comparativa del pronóstico del método de R.L. contra RNA

En las gráficas de las figuras 4.40 y 4.41 se observa que con el método de redes neuronales se obtiene el pronóstico con mayor precisión, ya que los errores que se presentan son menores que con los otros métodos, tanto para el ajuste como para el pronóstico.

#### 4.7 Región Arábiga de Dhaharán

Para esta simulación, se muestran los datos de la región Arábiga de Dhaharán, con las variables climatológicas de la región y el crecimiento medio de la población y la demanda de energía registrada de agosto de 1987 a julio de 1992. Los cuales se presentan a continuación; ver “Anexo G”.




Figura 4.42. Gráfica de la demanda media mensual, para la región Arábiga.




Figura 4.43 Gráfica de la temperatura media mensual, para la región Árabiya.




Figura 4.44 Gráfica de la humedad media mensual, para la región Árabiya.




Figura 4.45 Gráfica del crecimiento mensual de la población, para la región Árabiya.




Figura 4.46 Gráfica de la radiación solar media mensual, para la región Arábiga.

Como en los ejemplos anteriores, cada variable se trató independientemente para obtener una estandarización dentro de  $[0,+1]$ , ver “Anexo L”. Aquí mismo se presentan los 72 meses que fueron analizados, de los cuales se utilizaron los seis últimos para comparar el resultado del pronóstico obtenido. Estos valores se encuentran dentro del área sombreada de la siguiente gráfica.




Figura 4.47. Gráfica de los datos estandarizados, para la región Arábiga.

Tabla 4.28.- Niveles de correlación para la región Arábiga

Variable	Correlación con la Demanda.
Temperatura	0.7080
Población	0.4486
Humedad	-0.4420
Rad. Solar	0.6237

También se presentan los niveles de correlación ya que muestran la manera en que influye cada variable en la demanda, lo cual ayuda en el análisis y selección de cada variable, esto se puede apreciar en la gráfica de la figura 4.47.

#### 4.7.1 Ajuste de datos de la región arábiga

Como se ha venido haciendo, se presentarán los resultados obtenidos con los programas desarrollados para resolver el problema del pronóstico por los distintos métodos que se están analizando, los resultados alcanzados se presentan en valores de P.U. para establecer los mismos rangos en todas las simulaciones, con una base de 1200 MWh.

##### 4.7.1.1 Ajuste de datos con regresión lineal

Al igual que en los ejemplos anteriores, se presentan primeramente los resultados obtenidos con el método de regresión lineal, y posteriormente, se muestra el error absoluto acumulado y el error medio absoluto.

Tabla 4.29.- Valores obtenidos durante el ajuste mediante regresión lineal.

	Real	Obten.	Error	% e		Real	Obten.	Error	% e		Real	Obten.	Error	% e
1	0.7333	0.724	0.0093	1.27	23	0.6667	0.719	-0.0523	-7.84	45	0.6667	0.6958	-0.0292	-4.38
2	0.6667	0.7049	-0.0382	-5.73	24	0.7333	0.767	-0.0337	-4.6	46	0.65	0.769	-0.119	-18.31
3	0.5833	0.6585	-0.0751	-12.88	25	0.8333	0.7838	0.0496	5.95	47	0.65	0.7842	-0.1342	-20.64
4	0.5	0.601	-0.101	-20.2	26	0.8	0.7674	0.0326	4.08	48	0.8	0.8322	-0.0322	-4.03
5	0.5333	0.5318	0.0016	0.29	27	0.6667	0.7237	-0.057	-8.55	49	0.8667	0.849	0.0177	2.04
6	0.5167	0.4556	0.0611	11.82	28	0.6667	0.6662	0.0004	0.07	50	0.8067	0.8326	-0.0259	-3.21
7	0.5067	0.4605	0.0462	9.12	29	0.5433	0.597	-0.0536	-9.87	51	0.85	0.7889	0.0611	7.19
8	0.54	0.5347	0.0053	0.98	30	0.5333	0.5208	0.0125	2.35	52	0.7333	0.7314	0.0019	0.26
9	0.7333	0.598	0.1353	18.45	31	0.6167	0.5257	0.091	14.76	53	0.6333	0.6622	-0.0288	-4.55
10	0.8	0.6712	0.1288	16.1	32	0.5	0.5999	-0.0999	-19.99	54	0.6167	0.586	0.0307	4.97
11	0.8167	0.6864	0.1303	15.96	33	0.5167	0.6632	-0.1466	-28.37	55	0.7	0.5909	0.1091	15.59
12	0.8333	0.7344	0.0989	11.87	34	0.7	0.7364	-0.0364	-5.2	56	0.6667	0.6651	0.0015	0.23
13	0.8	0.7512	0.0488	6.1	35	0.6667	0.7516	-0.0849	-12.73	57	0.7	0.7284	-0.0284	-4.06
14	0.7667	0.7348	0.0319	4.16	36	0.8333	0.7996	0.0337	4.04	58	0.7	0.8016	-0.1016	-14.52
15	0.6667	0.6911	-0.0244	-3.66	37	0.8667	0.8164	0.0503	5.8	59	0.9	0.8168	0.0832	9.25
16	0.6	0.6336	-0.0336	-5.6	38	0.8	0.8	0	0	60	0.9667	0.8648	0.1018	10.53
17	0.5333	0.5644	-0.031	-5.82	39	0.8333	0.7563	0.077	9.25	61	1	0.8816	0.1184	11.84
18	0.5333	0.4882	0.0451	8.46	40	0.7333	0.6988	0.0345	4.71	62	0.9	0.8652	0.0348	3.87
19	0.5167	0.4931	0.0236	4.57	41	0.6333	0.6296	0.0038	0.59	63	0.7667	0.8215	-0.0548	-7.15
20	0.4667	0.5673	-0.1007	-21.57	42	0.6	0.5534	0.0466	7.77	64	0.75	0.764	-0.014	-1.87
21	0.55	0.6306	-0.0806	-14.66	43	0.5333	0.5583	-0.0249	-4.68	65	0.7333	0.6948	0.0386	5.26
22	0.6333	0.7038	-0.0705	-11.13	44	0.5	0.6325	-0.1325	-26.51	66	0.6667	0.6186	0.0481	7.21

Error total absoluto (en porciento)= 8.14

Error medio absoluto (P.U.)= 0.0559






Figura 4.48 Gráfica del ajuste con regresión lineal para la región arábiga.

#### 4.7.1.2 Ajuste de datos con VAR

A continuación, se muestran los resultados obtenidos durante el ajuste para este método.




Figura 4.49 Gráfica del ajuste y el pronóstico con VAR. Para la región arábiga.

Tabla 4.30 .- Valores obtenidos durante el ajuste mediante VAR.

	Real	Obten.	Error	% e		Real	Obten.	Error	% e		Real	Obten.	Error	% e
1	0.7333	0.7240	0.0093	1.27	23	0.6667	0.7190	-0.0523	-7.85	45	0.6667	0.6958	-0.0292	-4.38
2	0.6667	0.7049	-0.0382	-5.74	24	0.7333	0.7670	-0.0337	-4.60	46	0.6500	0.7690	-0.1190	-18.31
3	0.5833	0.6585	-0.0752	-12.89	25	0.8333	0.7838	0.0495	5.95	47	0.6500	0.7842	-0.1342	-20.64
4	0.5000	0.6010	-0.1010	-20.20	26	0.8000	0.7674	0.0326	4.08	48	0.8000	0.8322	-0.0322	-4.03
5	0.5333	0.5318	0.0015	0.29	27	0.6667	0.7237	-0.0570	-8.55	49	0.8667	0.8490	0.0177	2.04
6	0.5167	0.4556	0.0611	11.82	28	0.6667	0.6662	0.0004	0.06	50	0.8067	0.8326	-0.0259	-3.21
7	0.5067	0.4605	0.0462	9.12	29	0.5433	0.5970	-0.0536	-9.87	51	0.8500	0.7889	0.0611	7.19
8	0.5400	0.5347	0.0053	0.98	30	0.5333	0.5208	0.0125	2.35	52	0.7333	0.7314	0.0019	0.26
9	0.7333	0.5980	0.1353	18.45	31	0.6167	0.5257	0.0910	14.76	53	0.6333	0.6622	-0.0289	-4.56
10	0.8000	0.6712	0.1288	16.10	32	0.5000	0.5999	-0.0999	-19.99	54	0.6167	0.5860	0.0307	4.98
11	0.8167	0.6863	0.1303	15.96	33	0.5167	0.6633	-0.1466	-28.37	55	0.7000	0.5909	0.1091	15.59
12	0.8333	0.7345	0.0989	11.87	34	0.7000	0.7364	-0.0364	-5.20	56	0.6667	0.6651	0.0015	0.23
13	0.8000	0.7511	0.0489	6.11	35	0.6667	0.7516	-0.0849	-12.74	57	0.7000	0.7284	-0.0284	-4.06
14	0.7667	0.7348	0.0319	4.16	36	0.8333	0.7996	0.0337	4.04	58	0.7000	0.8016	-0.1016	-14.51
15	0.6667	0.6911	-0.0244	-3.66	37	0.8667	0.8164	0.0503	5.80	59	0.9000	0.8167	0.0833	9.25
16	0.6000	0.6336	-0.0336	-5.60	38	0.8000	0.8000	0.0000	0.00	60	0.9667	0.8649	0.1018	10.53
17	0.5333	0.5644	-0.0310	-5.82	39	0.8333	0.7563	0.0771	9.25	61	1.0000	0.8815	0.1185	11.85
18	0.5333	0.4882	0.0451	8.46	40	0.7333	0.6988	0.0345	4.71	62	0.9000	0.8652	0.0348	3.87
19	0.5167	0.4931	0.0236	4.57	41	0.6333	0.6295	0.0038	0.60	63	0.7667	0.8215	-0.0548	-7.15
20	0.4667	0.5674	-0.1007	-21.58	42	0.6000	0.5534	0.0466	7.77	64	0.7500	0.7641	-0.0141	-1.87
21	0.5500	0.6307	-0.0807	-14.67	43	0.5333	0.5583	-0.0250	-4.68	65	0.7333	0.6948	0.0386	5.26
22	0.6333	0.7038	-0.0705	-11.12	44	0.5000	0.6325	-0.1325	-26.51	66	0.6667	0.6186	0.0481	7.21


Con los resultados obtenidos se calcularon el error absoluto acumulado y el error medio absoluto.

$$\text{Error total absoluto (en porciento)} = 8.14$$

$$\text{Error medio absoluto (P.U.)} = 0.0559$$

#### 4.7.1.3 Ajuste de datos con RNA

En la siguiente figura se presentan los resultados logrados durante el ajuste con el método de R.N.A. para la región Arábiga, en esta gráfica se muestran los resultados, el valor real y en la parte inferior de dicha gráfica se muestra el error alcanzado para cada evento.



*Figura 4.50 Gráfica del ajuste utilizando RNA, para la región árabe.*

A continuación se muestra el error absoluto acumulado y el error medio absoluto obtenidos durante el ajuste:

Error total absoluto (en porciento)= 1.60

Error medio absoluto (P.U.)= 0.0110

Tabla 4.31 .- Valores obtenidos durante el ajuste mediante VAR.

	Real	Obten.	Error	% e		Real	Obten.	Error	% e		Real	Obten.	Error	% e
1	0.7333	0.7369	-0.0036	-0.49	23	0.6667	0.6563	0.0103	1.55	45	0.6667	0.6591	0.0075	1.13
2	0.6667	0.6596	0.0070	1.05	24	0.7333	0.7348	-0.0015	-0.21	46	0.6500	0.6397	0.0103	1.58
3	0.5833	0.5789	0.0044	0.76	25	0.8333	0.8467	-0.0133	-1.60	47	0.6500	0.6384	0.0116	1.79
4	0.5000	0.5256	-0.0256	-5.12	26	0.8000	0.8133	-0.0133	-1.67	48	0.8000	0.8111	-0.0111	-1.39
5	0.5333	0.5437	-0.0104	-1.95	27	0.6667	0.6598	0.0069	1.03	49	0.8667	0.8762	-0.0096	-1.10
6	0.5167	0.5341	-0.0174	-3.37	28	0.6667	0.6600	0.0067	1.01	50	0.8067	0.8204	-0.0137	-1.70
7	0.5067	0.5288	-0.0221	-4.37	29	0.5433	0.5500	-0.0067	-1.23	51	0.8500	0.8624	-0.0124	-1.46
8	0.5400	0.5477	-0.0077	-1.42	30	0.5333	0.5436	-0.0103	-1.93	52	0.7333	0.7376	-0.0043	-0.59
9	0.7333	0.7368	-0.0034	-0.47	31	0.6167	0.6081	0.0085	1.38	53	0.6333	0.6246	0.0087	1.37
10	0.8000	0.8115	-0.0115	-1.43	32	0.5000	0.5255	-0.0255	-5.10	54	0.6167	0.6082	0.0085	1.38
11	0.8167	0.8275	-0.0109	-1.33	33	0.5167	0.5337	-0.0171	-3.30	55	0.7000	0.6980	0.0020	0.29
12	0.8333	0.8450	-0.0116	-1.40	34	0.7000	0.6958	0.0042	0.60	56	0.6667	0.6597	0.0070	1.05
13	0.8000	0.8130	-0.0130	-1.63	35	0.6667	0.6563	0.0103	1.55	57	0.7000	0.6973	0.0027	0.39
14	0.7667	0.7763	-0.0097	-1.26	36	0.8333	0.8450	-0.0116	-1.40	58	0.7000	0.6958	0.0042	0.60
15	0.6667	0.6598	0.0069	1.03	37	0.8667	0.8762	-0.0096	-1.10	59	0.9000	0.8994	0.0006	0.06
16	0.6000	0.5931	0.0069	1.15	38	0.8000	0.8133	-0.0133	-1.67	60	0.9667	0.9382	0.0284	2.94
17	0.5333	0.5437	-0.0104	-1.95	39	0.8333	0.8471	-0.0138	-1.65	61	1.0000	0.9526	0.0474	4.74
18	0.5333	0.5436	-0.0103	-1.93	40	0.7333	0.7376	-0.0043	-0.59	62	0.9000	0.9016	-0.0016	-0.17
19	0.5167	0.5340	-0.0174	-3.36	41	0.6333	0.6246	0.0087	1.37	63	0.7667	0.7765	-0.0099	-1.29
20	0.4667	0.5112	-0.0445	-9.54	42	0.6000	0.5930	0.0070	1.17	64	0.7500	0.7573	-0.0073	-0.98
21	0.5500	0.5538	-0.0038	-0.70	43	0.5333	0.5436	-0.0103	-1.92	65	0.7333	0.7377	-0.0044	-0.60
22	0.6333	0.6226	0.0108	1.70	44	0.5000	0.5255	-0.0255	-5.10	66	0.6667	0.6598	0.0069	1.03

#### 4.7.1.4 Resultados obtenidos durante el ajuste

En la siguiente tabla se presenta una evaluación a los métodos seleccionados, indicando el error total absoluto dado de manera porcentual, el error medio absoluto para cada caso:

Tabla 4.32.- Resultados obtenidos para la región Arábiga.

Caso	Error	
	Total Absoluto %	Medio Absoluto (P.U)
RNA	1.60	0.0110
R.L.	8.14	0.0559
VAR.	8.14	0.0559

Las evaluaciones del error presentados para los distintos métodos analizados, tiene el fin de dar criterios de desempeño para el empleo del pronóstico, así mismo se puede observar que el mejor de los pronósticos fue el calculado mediante RNA.

#### 4.7.2 Pronóstico de la demanda en la región arábiga

Continuando con este caso, se presentan los pronósticos alcanzados para los próximos 6 meses, con los programas desarrollados para cada método. Se grafican dichos resultados, a fin de visualizar los pronósticos citados, cabe mencionar que los pronósticos que se obtuvieron se dan en valores de P.U. para establecer los mismos rangos en cada simulación, con base de 1200 MW.

##### 4.7.2.1 Pronóstico con Regresión Lineal

A continuación se presentan los valores del pronóstico obtenido con este método.




Figura 4.51 Gráfica del pronóstico con regresión lineal para la región arábiga

Para reforzar la gráfica anterior, se presenta la siguiente tabla con los resultados del pronóstico alcanzado por este método.

Tabla 4.33.- Pronóstico de la demanda mediante el método de Regresión lineal.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.7167	0.6235	0.0932	13.00
2	0.7333	0.6977	0.0356	4.85
3	0.7500	0.7610	-0.0110	-1.47
4	0.7400	0.8342	-0.0942	-12.73
5	0.9333	0.8494	0.0840	9.00
6	0.9000	0.8974	0.0026	0.28

El error absoluto acumulado y el error medio absoluto, se presentan a continuación.

$$\text{Error total absoluto (en porciento)} = 6.71$$

$$\text{Error medio absoluto (P.U.)} = 0.0534$$

#### 4.7.2.2 Pronóstico con VAR

En la siguiente gráfica se presentan los valores del pronóstico logrado por este método.




Figura 4.52. Gráfica del pronóstico alcanzado con VAR para la región arábiga.

A continuación se dan en la siguiente tabla, los resultados del pronóstico alcanzado con el programa desarrollado para este método.

Tabla 4.34.- Pronóstico de la demanda mediante el método de VAR.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.7167	0.6235	0.0932	13.00
2	0.7333	0.6978	0.0356	4.85
3	0.7500	0.7611	-0.0111	-1.48
4	0.7400	0.8342	-0.0942	-12.73
5	0.9333	0.8494	0.0839	8.99
6	0.9000	0.8974	0.0026	0.28

Con los resultados del pronóstico alcanzado, se calculó el error absoluto acumulado y el error medio absoluto, los cuales se presentan a continuación.

$$\text{Error total absoluto (en por ciento)} = 6.71$$

$$\text{Error medio absoluto (P.U.)} = 0.0534$$

#### 4.7.2.3 Pronóstico con RNA

En la figura 4.53, se muestra el pronóstico obtenido con el programa desarrollado para resolver este problema mediante RNA.




Figura 4.53. Gráfica del pronóstico alcanzado con RNA, para la región arábica.

En la siguiente tabla se presentan los valores del pronóstico logrado mediante el método de RNA, mostrándose el error para cada evento.

Tabla 4.35.- Pronóstico de la demanda mediante el método de RNA.

	Demanda PU	Valor Obtenido PU	Error	Error %
1	0.7167	0.7571	-0.0405	-5.65
2	0.7333	0.7176	0.0158	2.15
3	0.7500	0.7564	-0.0064	-0.86
4	0.7400	0.7550	-0.0150	-2.02
5	0.9333	0.9297	0.0037	0.39
6	0.9000	0.9576	-0.0576	-6.40

Con los valores del pronóstico logrado, se calcularon los errores absoluto acumulado, el error medio absoluto, los que se muestran a continuación.

$$\text{Error Total absoluto (en porciento)}= 2.91$$

$$\text{Error Medio absoluto (P.U.)}= 0.0231$$

#### 4.7.2.4 Resultados obtenidos

En la siguiente tabla se presenta una evaluación de los pronósticos obtenidos con los métodos indicados, estas evaluaciones tienen el fin de dar criterios de desempeño para su uso, así mismo se puede observar que el mejor de los pronósticos fue el calculado mediante RNA:

Tabla 4.36.- Resultados obtenidos para la región Arábiga.

Caso	Error	
	Total Absoluto %	Medio Absoluto (P.U.)
RNA	2.91	0.0231
R.L.	6.71	0.0534
VAR.	6.71	0.0534

#### 4.7.3 Comparación de resultados

Por último, se comparan los métodos de R.L. y el de RNA, con el fin mostrar gráficamente que el pronóstico que más se aproxima a la realidad, siendo el que se obtiene con la red neuronal de tres capas, alimentada con la demanda y la humedad, contando con dos neuronas en la capa de entrada siete en la oculta y una en la capa de salida, en la figura 4.54 se muestra una comparación entre dichos métodos. Para resaltar que durante el ajuste el método de RNA fue el más próximo.




Figura 4.54. Gráfica comparativa del ajuste del método de R.L. contra RNA




Figura 4.55. Gráfica comparativa del pronóstico alcanzado entre el método de R.L. y RNA

En estas gráficas se puede observar que el método de redes neuronales, pronostica con mayor precisión la demanda de energía eléctrica, pues los errores que se presentan son menores que con los otros métodos, tanto durante el ajuste como en el pronóstico. Entonces el método de RNA resulta ser el que da mejor solución al problema del pronóstico.



#### 4.8 Análisis del estudio

- ✓ De las simulaciones que se efectuaron en este capítulo, se ha observado que los diferentes métodos tienen la suficiente aceptación para diferentes objetivos y necesidades. Es decir, que el mejor pronóstico se puede aproximar lo suficiente durante el ajuste de la curva, sin embargo, factores ajenos a las variables analizadas pueden afectar el comportamiento de la demanda, ya que se está sujeto a los sucesos futuros los cuales no pueden ser conocidos de antemano. Sin embargo, el pronóstico es indispensable para la operación y planeación de los SEP.
  
- ✓ Por otro lado, el comportamiento de las distintas simulaciones depende de gran medida de la región, ya que de ella se podrá analizar el comportamiento del crecimiento de la población, actividad económica entre otras variables, puesto que el comportamiento de la curva característica de la demanda, no será siempre ascendente como se pudo apreciar en la región del istmo, este fenómeno se puede presentar por distintas razones, tal vez un decremento en el crecimiento poblacional o una desaceleración en la economía de dicha región, por lo cual este tipo de factores debe ser integrado al estudio del pronóstico de la demanda.
  
- ✓ El preprocesamiento efectuado a los datos en cada una de las simulaciones fue beneficioso al pronóstico, ya que permitió que los resultados se centrasen en las variables más relevantes. Es decir, que con el preprocesamiento se cambia la interpretación y el planteamiento del problema, como en los casos estudiados, de hecho, que se pase de la “predicción de la demanda” a “la predicción de los motivos del cambio de la demanda en relación a las variables, de los eventos históricos”.

- ✓ En los resultados obtenidos, no basta con el análisis de correlación para la selección de las variables ya que para el caso de RNA no fueron los mejores resultados los obtenidos con las variables que presentaron los índices de correlación más altos. Sin embargo, para el método de regresión lineal y autorregresivo, el análisis de correlación de las variables, fue fundamental ya que, al ajustar la curva de la demanda empleando una sola variable, el mejor ajuste se logro con la variable que presenta la mayor correlación, así mismo se alcanzo un mejor ajuste empleando todas las variables empleadas.
  
- ✓ Todas las simulaciones realizadas en este trabajo, están enfocadas a la solución del pronóstico de la demanda de energía eléctrica, sin embargo, los modelos analizados son extrapolables a cualquier otro tipo de problema de pronóstico de series temporales o síntesis de funciones.

#### **4.8.1 Regresión lineal**

- ✓ Este método es sencillo y fácil de implementar, ya que tiene la flexibilidad de considerar distintas variables para realizar el estudio del pronóstico. Este no es un método robusto por lo cual la curva característica de la demanda debe presentar una uniformidad en sus datos sin variaciones considerables.
  
- ✓ Como se dijo anteriormente, para este método el análisis de correlación de las variables es fundamental ya que, al emplear una sola variable, el mejor ajuste resulta con la variable que presenta la mayor correlación. Del mismo modo se logró un mejor ajuste al emplear todas las variables, con lo que se puede decir que, para este método, el resultado del ajuste es proporcional a la correlación de las variables que se incluyen.

- ✓ Los métodos de regresión son sencillos y fáciles de aplicar para diferentes tipos de problemas, como por ejemplo para el caso de la región norte. Sin embargo la naturaleza de los datos y el objetivo del pronóstico darán la pauta para realizar una regresión y poder efectuar un pronóstico. Ya que de no ser aplicado el mejor modelo se pueden duplicar valores o no considerar datos, que pueden llevar a una mala estimación. Como se pudo observar en las otras regiones.
  
- ✓ Esta clase de métodos ha cobrado popularidad debido al gran número de paquetes comerciales estadísticos que lo incluyen y por ser un proceso que se adapta a un sinnúmero de aplicaciones que permiten la toma de decisiones.

#### **4.8.2 Método autorregresivo**

- ✓ Al igual que para el método de R.L. el análisis de correlación de las variables es fundamental para éste método, ya que el mejor ajuste resulta ser el obtenido con la variable que presenta la mayor correlación y al emplear todas las variables implicadas se logra un mejor ajuste, así mismo éste resultado es proporcional a la correlación de las variables que se incluyen.
  
- ✓ Con lo cual se puede concluir que el pronóstico realizado con todas las variables, presenta mayor precisión en la solución del problema del pronóstico, como se pudo apreciar en el ejemplo de la región norte.
  
- ✓ Sin embargo, se puede observar en los ajustes realizados para las otras regiones, que no se presentaron resultados favorables, por lo cual en este trabajo no se puede seleccionar el modelo autorregresivo como el modelo ideal para el pronóstico de la demanda.

### 4.8.3 Redes neuronales artificiales

- ✓ Este método al igual que los anteriores, también es sencillo de implementar; sin embargo, presenta grandes ventajas con respecto a modelos típicos que dan solución al problema de pronóstico de la demanda de energía eléctrica, una de ellas es su inspiración en el funcionamiento del cerebro humano, lo que facilita su estudio debido a las analogías que pueden llevar a la solución de problemas de este tipo, que no pueden ser solucionados por otros métodos.
  
- ✓ Durante el desarrollo de este trabajo se pudo constatar que en comparación con los otros métodos analizados, las RNA se ajustaron con mayor precisión a los datos reales, así mismo, se aproximaron con menor margen de error a los valores reales del pronóstico.
  
- ✓ Las RNA constituyen un método demasiado creativo para la solución del problema del pronóstico, es decir, dadas las especificaciones del problema, se desconoce la topología de la red, que dará solución al problema de la manera más eficiente, por lo que, como se mencionó al principio del capítulo hay que emplear el método de prueba y error, durante la implementación y entrenamiento de la red, con lo cual se encuentra la topología que da la mejor solución al problema de pronóstico.
  
- ✓ En la siguiente tabla, se puede apreciar que para los cuatro casos se encontró que la red que mejor se ajusta a la curva de la demanda de energía eléctrica, es la red de tres capas y para cada caso se encontró un punto óptimo de la red para el ajuste, definiendo la topología de la red, para cada caso como se muestra la tabla, cuando se llegó a dicho punto en que ya no se mejora el ajuste y se incrementaba el tiempo de proceso del ajuste de la curva.

Tabla 4.37.- Resultados obtenidos para cada región, con su topología.

Región	Error				Topología de la RNA	Variables utilizadas
	Total abs. %		Medio abs. P.U.			
	Ajuste	Pronóstico	Ajuste	Pronóstico		
Norte	0.97	1.84	0.0069	0.0150	3-8-1	Todas en Cascada
Sur	0.35	2.72	0.0027	0.0253	2-8-1	Temperatura y Demanda
Istmo	1.48	3.80	0.0109	0.0318	2-7-1	Temperatura y Demanda
Arábiga	1.60	2.91	0.0110	0.0231	2-7-1	Humedad y Demanda

- ✓ Por la gran cantidad de procesos que realiza la RNA es difícil averiguar por que en determinado momento la RNA no converge, por lo tanto se busca, operar la red con distintas variables en forma independiente, combinadas o en forma de cascada para discriminar variables que no colaboran en la solución del problema.
  
- ✓ Una vez que la red neuronal se entrenó, es difícil interpretar su funcionamiento por lo cual se considera como una caja negra a la cual entran valores y sale un valor esperado.

# CAPÍTULO V

## **CONCLUSIONES Y RECOMENDACIONES**

## 5.1 Resumen de aspectos generales

El problema del pronóstico no es un problema nuevo, éste surgió desde el momento mismo en que se establecieron las compañías de SEP, sólo que cada vez se le ha ido dando más importancia, ya que el pronóstico es empleado cada vez más durante la planeación estratégica, expansión y operación de los SEP. Por lo tanto, este problema se considera del interés para toda compañía de electricidad, por lo cual se han desarrollado diversos métodos de pronóstico. Por otro lado, si los pronósticos realizados se apegan lo suficiente a la realidad, se aportarán un sin número de parámetros útiles para la planeación evitando amenazas en el exceso o baja capacidad de producción.

Y para que un pronóstico sea aceptable, la credibilidad del mismo debe ser determinada, Así, un modelo de pronóstico debe considerar un conjunto de criterios que se utilizarán para medir el desempeño de éste. Estableciendo estándares para pronósticos futuros, y para que el usuario conozca la precisión y debilidad del pronóstico. Por lo tanto, la evaluación del desempeño del pronóstico es de gran importancia, en medida de que se proporcione información sobre la demanda futura, siendo esencial informar, del riesgo asociado al pronóstico, y brindar un resumen de los errores del modelo empleado. Lo anterior, es importante ya que permite al usuario conocer la incertidumbre del pronóstico, para planear estrategias dentro de su horizonte establecido.

Cabe recordar que detrás de los errores de pronóstico existen distintos problemas, como por ejemplo errores de especificación del modelo, errores en la estimación de los parámetros, perturbaciones atípicas, errores en las proyecciones de las variables independientes y errores de medición de las variables dependientes, dicho lo anterior se puede recordar que *“La importancia del pronóstico es evidente. Y la imposibilidad de desarrollar pronósticos verdaderamente exactos deberá ser admitida. Simplemente debemos aceptar que no podemos prever el futuro”*.

## **5.2 Conclusiones del estudio del Pronóstico de la demanda de energía eléctrica**

En este trabajo se analizó el método de redes neuronales artificiales por retropropagación del error aplicado al problema del pronóstico de la demanda de energía eléctrica; así mismo, se comparan los resultados obtenidos con el método de regresión lineal y autorregresivo, los cuales implican grados diferentes de complejidad y suponen niveles diferentes de comprensión. De los ejemplos que se efectuaron, se observó que los diferentes métodos tienen la suficiente aceptación para diferentes objetivos y necesidades, es decir que el comportamiento de la demanda está sujeto a sucesos futuros los cuales no pueden ser pronosticados.

Todas las simulaciones realizadas en este capítulo, están enfocadas a la solución del pronóstico de la demanda de energía eléctrica a mediano plazo; sin embargo, los modelos analizados en este trabajo son extrapolables a cualquier otro tipo de problema de pronóstico de series temporales o síntesis de funciones.

Antes de resolver el problema del pronóstico, éste debe comprenderse totalmente, siendo por lo general más complejo de lo que parece. Y tras haber presentado abundante información del pronóstico, de las RNA y con los resultados que se alcanzaron en el capítulo anterior, se llegó a las siguientes conclusiones:

### **5.2.1 Para el método de regresión lineal**

- ✓ Como ya se dijo este método es sencillo y fácil de implementar, ya que tiene la flexibilidad de considerar distintas variables para realizar el estudio del pronóstico. Este no es un método robusto por lo cual la curva característica de la demanda no debe presentar grandes fluctuaciones en sus datos.
  
- ✓ Así mismo con el análisis de correlación de las variables con la demanda de energía eléctrica, el problema del pronóstico se beneficia, ya que permite que la solución del pronóstico se centre en las variables que más influyen con la demanda de energía eléctrica, encontrando que para este método el nivel de correlación y el número de variables incluidas influyen directamente en la solución del problema del pronóstico.



- ✓ Los métodos de regresión son sencillos y fáciles de aplicar para diferentes tipos de problemas, como por ejemplo para los casos de la región norte y sur; sin embargo, la naturaleza de los datos y el objetivo del pronóstico darán la pauta para realizar una regresión y poder efectuar un pronóstico. Ya que de no ser el correcto se pueden duplicar valores o no considerar datos, que pueden llevar a una mala estimación. Como se pudo observar en los de las otras regiones, y como se puede apreciar en la siguiente tabla:

Tabla 5.1 Resultados obtenidos, por medio de regresión lineal.

Región	Error			
	Total abs. %		Medio abs. P.U.	
	Ajuste	Pronóstico	Ajuste	Pronóstico
Norte	2.49	2.99	0.0170	0.0250
Sur	2.01	4.19	0.0159	0.0389
Istmo	11.26	9.45	0.0831	0.0791
Arábiga	8.14	6.71	0.0559	0.0534

- ✓ Sin embargo, este método ha cobrado popularidad debido al gran número de paquetes comerciales estadísticos que lo incluyen y por ser un proceso que se adapta a un sinnúmero de aplicaciones que permiten la toma de decisiones.

### 5.2.2 Método autorregresivo

- ✓ Los modelos autorregresivos son útiles para el problema de pronóstico, ya que al igual que el método de R.L. El análisis de correlación de las variables con la demanda, beneficia el problema del pronóstico, ya que permite que la solución del pronóstico se centre en las variables que más influyen con la demanda de energía eléctrica, encontrando que para este método el nivel de correlación y las variables incluidas influyen directamente en la solución del problema del pronóstico.

- ✓ Sin embargo, se puede observar, que en el ajuste realizado para las regiones norte y sur se alcanzan mejores resultados que para las otras regiones, por lo cual este método no es el ideal para resolver el problema del pronóstico de la demanda, en regiones como la Arábiga o Istmo.
  
- ✓ Este método al igual que el de regresión, es sencillo y fácil de aplicar, como por ejemplo, para los casos de la región norte y sur; sin embargo, la naturaleza de los datos y el objetivo del pronóstico darán la pauta para aplicar este método y poder efectuar un pronóstico. Ya que de no ser el correcto, puede llevar a tomar una mala estimación. Como se puede apreciar en la siguiente tabla

Tabla 5.2 Resultados obtenidos, por medio de VAR.

Región	Error			
	Total abs. %		Medio abs. P.U.	
	Ajuste	Pronóstico	Ajuste	Pronóstico
Norte	2.49	2.99	0.0170	0.0250
Sur	1.99	4.14	0.0158	0.0385
Istmo	11.19	11.14	0.0825	0.0932
Arábiga	8.14	6.71	0.0559	0.0534

### 5.2.3 Redes neuronales artificiales

- ✓ Las RNA presentan grandes ventajas con respecto a los métodos regresivos y autorregresivos, ya que dan la mejor solución al problema de pronóstico de la demanda de energía eléctrica. Una de las ventajas de este método, es su inspiración en modelos biológicos del funcionamiento del cerebro humano, lo que facilita su estudio debido a las analogías que pueden introducirse para su análisis

- ✓ Este método, al igual que los anteriores es sencillo de implementar, ya que tiene la flexibilidad de considerar distintas variables para realizar el estudio, tendiente a la solución del problema de pronóstico de la demanda de energía eléctrica a mediano plazo.
  
- ✓ El modelo matemático en que se desarrolla el algoritmo de la red neuronal con retropropagación del error en particular, es en general sencillo, este modelo puede ser asimilado para el desarrollo de un programa de cómputo con cierta facilidad.
  
- ✓ Este método es uno de los más confiables que existe, y durante el desarrollo de este trabajo, se constató que en comparación con los métodos mencionados, es el más preciso para resolver el problema del pronóstico. Por lo que para este caso, se considera al método de redes neuronales como el más eficiente para el estudio del pronóstico de la demanda de energía eléctrica de los métodos analizados.
  
- ✓ Y al ser el que más se aproxima a la realidad, se puede aplicar en diferentes tipos de problemas, siendo los resultados con menor error para cada una de los ejemplos. Lo cual se puede observar en la siguiente tabla:

Tabla 5.3 Resultados obtenidos, por medio de RNA.

Región	Error			
	Total abs. %		Medio abs. P.U.	
	Ajuste	Pronóstico	Ajuste	Pronóstico
Norte	0.97	1.84	0.0069	0.0150
Sur	0.35	2.72	0.0027	0.0253
Istmo	1.48	3.80	0.0109	0.0318
Arábiga	1.60	2.91	0.0110	0.0231

- ✓ Sin embargo, puede parecer que por el tiempo que se lleva el entrenamiento de la RNA, los métodos, de regresión lineal y autorregresivos, pueden ser seleccionados para calcular el pronóstico. Para definir esta interrogante, es preciso plantear los objetivos del pronóstico y los beneficios que se obtendrán con dicho resultado, ya que la exactitud que se obtiene con RNA es superior a los otros métodos, lo cual contrarresta la desventaja del tiempo que implica el entrenamiento de la red.
  
- ✓ Durante el desarrollo de este trabajo se encontró que la arquitectura de la red ideal para la solución de este problema es la RNA, tipo Retropropagación del error con tres capas y deferentes neuronas en cada capa.
  
- ✓ Por ultimo, cabe recordar aquí, que no es posible la automatización completa del pronóstico ya que éste es un proceso que depende de sucesos futuros que ni el pronosticador más experto puede predecir.

### **5.3 Recomendaciones para trabajos futuros**

- ✓ Realizar el pronóstico con variables independientes que aquí no fueron empleadas, como son: los días festivos, huelgas, catástrofes, eventos deportivos, etc. Los cuales puede afectar el comportamiento de la demanda y provocar datos atípicos, los cuales puede que no sean percibidos con las variables analizadas en el presente trabajo.
  
- ✓ Que al resolver el problema del pronóstico, no se busque encontrar pronósticos mayores de 6 eventos, ya que se presentará un efecto acumulativo de los errores propios de la serie de tiempo.

- ✓ Este trabajo puede ser empleado como base para establecer desarrollos de aplicaciones con el empleo de métodos robustos que permitan una estimación de la demanda más eficiente, que la observada en este trabajo.
  
- ✓ Se recomienda el método de RNA, como un método que puede dar solución al problema de pronóstico de la demanda de energía eléctrica, sin embargo es necesario tener un entendimiento claro y profundo del problema en si, pues esto facilita la elección de la topología de la red.
  
- ✓ Así mismo, se recomiendan los métodos regresivos y autorregresivos como métodos alternativos para la solución del problema del pronóstico, cuando los objetivos y la naturaleza propia de la demanda lo permitan.
  
- ✓ Estudiar la posibilidad de emplear modelos combinados, ya que con uno de los métodos analizados posiblemente se obtenga un filtrando de alguna variable utilizada.
  
- ✓ Se plantea la idea de crear un método de pronóstico que implemente la aplicación de sistemas expertos, que incluya la experiencia de expertos en el área, toda vez que la interacción de algún método como la RNA en combinación con la experiencia de los encargados del pronóstico, puede brindar mejores resultados al pronóstico de la demanda.
  
- ✓ Así mismo, se trabaje con el establecimiento de un procedimiento que en combinación con Algoritmos Genéticos pueda encontrar la arquitectura ideal de la RNA, enfocada a la solución del pronóstico de la demanda de energía eléctrica.

**REFERENCIAS:**

- [1] J. Robles García, D. Romero R. y S. Peña S., “PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA UTILIZANDO EL MODELO DEL VECTOR AUTORREGRESIVO” Paper interno de SEPI.
- [2] J. Robles García, D. Romero R. y S. Peña S., “PRONÓSTICO DE LA DEMANDA UTILIZANDO REGRESIÓN LINEAL” RVP-AI/2000 julio 2000.
- [3] J. Riquelme, J.L. Martínez y A. Gómez, “POSIBILIDADES DE LAS REDES NEURONALES EN LA PREDICCIÓN DE LA DEMANDA ELÉCTRICA A CORTO PLAZO” Mercado Eléctrico M-1630 Sevilla.
- [4] M.C. Salvador Acha Daz, Tesis de maestría “METODOS PARA PRONÓSTICO DE LA DEMANDA A MEDIANO PLAZO EN SISTEMAS ELÉCTRICOS DE POTENCIA”, Sección de graduados de la ESIME del IPN. Marzo de 1982 México, D.F.
- [5] Saleh M. Al-Alawi y Syed M. Islam “PRINCIPLES OF ELECTRICITY DEMAND FORECASTING, PART 1, METODOLOGIES (TUTORIAL)”, Power engineering journal, june 1996.
- [6] Saleh M. Al-Alawi y Syed M. Islam “PRINCIPLES OF ELECTRICITY DEMAND FORECASTING, PART 2, APPLICATIONS (TUTORIAL)”, Power engineering journal, 1997.
- [7] J. Robles García, G. Allende S., “PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA UTILIZANDO REDES NEURONALES” RVP-2003 julio 2003.
- [8] J. Robles García, G. Allende S., “ESTUDIO COMPARATIVO DEL PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA UTILIZANDO REDES NEURONALES ARTIFICIALES”, 7o congreso nacional de ingeniería electromecánica y de sistemas, noviembre del 2003.
- [9] M.I. Acosta B. Y C.A. Zuluaga M. “TUTORIAL SOBRE REDES NEURONALES APLICADO EN INGENIERIA ELECTRICA Y SU IMPLEMENTACIÓN”, Universidad Tecnológica de Pereira 2000.
- [10] M. García Pellicer y A. Quijano López, “NUEVO CONCEPTO EN LA PREDICCIÓN DE DEMANDA DE ENERGÍA ELÉCTRICA”, Instituto Tecnológico Eléctrico de Valencia, Mercado Eléctrico K-1365.

- [11] C.W Gellings, "DEMAND FORECASTING FOR ELECTRIC UTILITIES", Published by The Fairmont Press, Inc. 1992.
- [12] Makridakis-Wheelwrioth. "MÉTODOS DE PRONÓSTICOS", Noriga Limusa, IPN. 1998.
- [13] Robert S. Pindyck. y Daniel L. Rubinfeld. "ECONOMETRÍA MODELOS Y PRONÓSTICOS", McGraw Hill, 2000.
- [14] M.C. Raúl Vilcahuaman S. Ing. Iván Medina C. e Ing. Antonio Téllez V., "SISTEMA EXPERTO PARA PRONÓSTICO DE LA DEMANDA"  
<http://www.continental.edu.pe/revista/articulos/pronos.htm>
- [15] EDWIN K.P. CHONG And STANISLAW H. ZAK, "AN INTRODUCTION TO OPTIMIZATION", WILEY INTERSCIENCE.
- [16] Malcolm R. Irving, Yong-Hua Song, "OPTIMISATION TECHNIQUES FOR ELECTRICAL POWER SYSTEMS, PART 1 MATHEMATICAL OPTIMIZATION METHODS", Power Engineering Journal October 2000.
- [17] Malcolm R. Irving, Yong-Hua Song, "OPTIMISATION TECHNIQUES FOR ELECTRICAL POWER SYSTEMS, PART 2 HEURISTIC OPTIMIZATION METHODS", Power Engineering Journal June 2001.
- [18] Luis G. Fonseca Guzmán, Severo López Arana, Mariano Órnelas López, "PRINCIPALES CUESTIONAMIENTOS A LA REFORMA ELÉCTRICA, RED ENERGETICA", AÑO 1, agosto 2002.
- [19] Secretaría de Energía, "PROSPECTIVA DEL SECTOR ELÉCTRICO 2003-2012", México, 2003.
- [20] Bernard Ostle, "ESTADISTICA APLICADA", Noriga Limusa, 2000.
- [21] Bowerman/ O'Connell, "FORECASTING AND TIME SERIES AN APPLIED APPROACH", Duxbury, 1993.
- [22] Helmut Lütkepohi, "INTRODUCTION TO MULTIPLE TIME SERIES ANALYSIS" Springer Verlag, 1988.
- [23] C. Chatfield, "THE ANALISIS OF TIME SERIES AN INTRODUCTION", Chapman and Hall, 1984.
- [24] Freeman, James A. y Skapura, David M. "REDES NEURONALES ALGORITMOS, APLICACIONES Y TÉCNICAS DE PROGRAMACIÓN", Addison-Wesley, Wilmintong, Delaware USA, 1993.

- [25] Bonifacio M. del Brio, Alfredo S. Molina, "REDES NEURONALES ARTIFICIALES Y SISTEMAS DIFUSOS", 2/a edición, Alfaomega-RAMA, 2002.
- [26] Enciclopedia Microsoft Encarta 2002.
- [27] José R. Hilera, Víctor J. Martínez, "REDES NEURONALES ARTIFICIALES, FUNDAMENTOS, MODELOS Y APLICACIONES.", Alfaomega-RAMA, 2000.
- [28] Richard A. Johnson, "PROBABILIDAD Y ESTADISTICA PARA INGENIEROS DE MILLAR Y FREUND", Prentice Hall, 1997.
- [29] Ei-Sharkawi, Mohamed and Niebur, Dagmar, "A TUTORIAL COURSE ON ARTIFICIAL NEURAL NETWORKS WITH APPLICATIONS TO POWER SYSTEMS", IEEE power engineering Society.
- [30] Alberto Solís O. Oscar L. Chacon M. "APLICACIÓN DE REDES NEURONALES ARTIFICIALES EN INGENIERIA ELECTRICA" RVP-94 EDU-08 julio 1994.
- [31] Y.-Yih Hsu, C-Chuen Yang, "DESING OF ARTIFICIAL NEURAL NETWORKS FOR SHORT TERM LOAD FORECSTING. PART I: SELF ORGANISING FEATURE MAPS FOR DAY TYPE IDENTIFICATION", IEE, 1991.
- [32] Y.-Yih Hsu, C-Chuen Yang, "DESING OF ARTIFICIAL NEURAL NETWORKS FOR SHORT TERM LOAD FORECASTING. PART II: MULTILAYER FEEDFORWARD NETWORKS FOR PEAK LOAD AND VALLEY LOAD FORECASTING", IEE, 1991
- [33] Juan G. Gómez G. Tesis de Licenciatura "PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA UTILIZANDO REDES NEURONALES ARTIFICIALES", Sección de graduados de la ESIME del IPN. Agosto del 2001 México, D.F
- [34] G.F.Filaretov, E.O. Averchenkov, "USING NEURAL NETS FOR TIME SERIES FORECASTING", Published IEEE, 1999.
- [35] P. Cortez, M. Rocha J. Machado y J. Neves, "A NEURAL NETWORK BASED TIME SERIES FORECASTING SYSTEMS", Published IEEE, 1995.
- [36] C. Chatfield, "TIME SERIES FORECASTING WITH NEURAL NETWORKS", Published IEEE, 1998.



# ANEXOS

## “ANEXO A”

**Tabla A.1.- Datos de la región norte en su estado normal.**

FECHA	TEMPERATURA	POBLACIÓN	HUMEDAD	DEMANDA
Ene-90	5.35	1639526.8	50.09	672
Feb-90	8.19	1642819.51	45.57	662
Mar-90	11.86	1646112.22	39.28	712
Abr-90	17.53	1649404.93	34.74	771
May-90	21.57	1652697.66	39.48	860
Jun-90	25.22	1655990.34	49.5	913
Jul-90	27.31	1662575.76	53.84	912
Ago-90	26.26	1665868.47	58.12	941
Sep-90	22.59	1669161.18	62.79	882
Oct-90	17.08	1672453.88	58.9	797
Nov-90	10.65	1675746.59	53.48	768
Dic-90	6.57	1679039.3	53.88	712
Ene-91	5.35	1682411.38	50.09	734
Feb-91	8.19	1685783.46	45.57	714
Mar-91	11.86	1689155.54	39.28	736
Abr-91	17.53	1692527.62	34.74	782
May-91	21.57	1695899.69	39.48	859
Jun-91	25.22	1699271.77	49.5	878
Jul-91	27.31	1702643.85	53.84	956
Ago-91	26.26	1706015.93	58.12	981
Sep-91	22.59	1709388.01	62.79	963
Oct-91	17.08	1712760.09	58.9	944
Nov-91	10.65	1716132.17	53.48	825
Dic-91	6.57	1719504.25	53.88	741
Ene-92	5.35	1722957.57	50.09	758
Feb-92	8.19	1726410.89	45.57	761
Mar-92	11.86	1729864.21	39.28	784
Abr-92	17.53	1733317.53	34.74	871
May-92	21.57	1736770.85	39.48	933
Jun-92	25.22	1740224.17	49.5	995
Jul-92	27.31	1743677.49	53.84	1071
Ago-92	26.26	1747130.82	58.12	1091
Sep-92	22.59	1750584.14	62.79	1023
Oct-92	17.08	1754037.46	58.9	1001
Nov-92	10.65	1757490.78	53.48	867
Dic-92	6.57	1760944.1	53.88	799
Ene-93	5.35	1764480.67	50.09	816
Feb-93	8.19	1768017.23	45.57	805
Mar-93	11.86	1771553.8	39.28	836
Abr-93	17.53	1775090.37	34.74	955
May-93	21.57	1778626.93	39.48	1004
Jun-93	25.22	1782163.5	49.5	1050
Jul-93	27.31	1785000	53.84	1100
Ago-93	26.26	1789000	58.12	1200
Sep-93	22.59	1792000	62.79	1073
Oct-93	17.08	1796000	58.9	1050
Nov-93	10.65	1799000	53.48	917
Dic-93	6.57	1803000	53.88	850

## “ANEXO B”

Tabla A.2.- Datos de la región norte estandarizados.

FECHA	TEMPERATURA	POBLACIÓN	HUMEDAD	DEMANDA
Ene-90	0	0	0.54723708	0.01858736
Feb-90	0.12932605	0.02014219	0.38609626	0
Mar-90	0.29644809	0.04028438	0.16185383	0.0929368
Abr-90	0.55464481	0.06042657	0	0.20260223
May-90	0.73861566	0.08056894	0.16898396	0.36802974
Jun-90	0.90482696	0.10071095	0.52620321	0.46654275
Jul-90	1	0.14099533	0.68092692	0.46468401
Ago-90	0.95218579	0.16113753	0.83351159	0.51858736
Sep-90	0.78506375	0.18127971	1	0.40892193
Oct-90	0.53415301	0.2014219	0.86131907	0.25092937
Nov-90	0.24134791	0.2215641	0.66809269	0.19702602
Dic-90	0.05555556	0.24170629	0.68235294	0.0929368
Ene-91	0	0.262334	0.54723708	0.133829
Feb-91	0.12932605	0.28296172	0.38609626	0.09665428
Mar-91	0.29644809	0.30358943	0.16185383	0.13754647
Abr-91	0.55464481	0.32421715	0	0.22304833
May-91	0.73861566	0.34484487	0.16898396	0.366171
Jun-91	0.90482696	0.36547259	0.52620321	0.40148699
Jul-91	1	0.3861003	0.68092692	0.5464684
Ago-91	0.95218579	0.40672801	0.83351159	0.5929368
Sep-91	0.78506375	0.42735573	1	0.55947955
Oct-91	0.53415301	0.44798345	0.86131907	0.52416357
Nov-91	0.24134791	0.46861116	0.66809269	0.30297398
Dic-91	0.05555556	0.48923888	0.68235294	0.14684015
Ene-92	0	0.51036357	0.54723708	0.17843866
Feb-92	0.12932605	0.53148827	0.38609626	0.18401487
Mar-92	0.29644809	0.55261296	0.16185383	0.2267658
Abr-92	0.55464481	0.57373765	0	0.38847584
May-92	0.73861566	0.59486234	0.16898396	0.50371747
Jun-92	0.90482696	0.61598704	0.52620321	0.61895911
Jul-92	1	0.63711173	0.68092692	0.76022305
Ago-92	0.95218579	0.65823643	0.83351159	0.79739777
Sep-92	0.78506375	0.67936112	1	0.67100372
Oct-92	0.53415301	0.70048582	0.86131907	0.63011152
Nov-92	0.24134791	0.72161051	0.66809269	0.38104089
Dic-92	0.05555556	0.7427352	0.68235294	0.25464684
Ene-93	0	0.76436913	0.54723708	0.28624535
Feb-93	0.12932605	0.78600305	0.38609626	0.26579926
Mar-93	0.29644809	0.80763697	0.16185383	0.32342007
Abr-93	0.55464481	0.8292709	0	0.54460967
May-93	0.73861566	0.85090481	0.16898396	0.63568773
Jun-93	0.90482696	0.87253874	0.52620321	0.72118959
Jul-93	1	0.88989021	0.68092692	0.81412639
Ago-93	0.95218579	0.91435905	0.83351159	1
Sep-93	0.78506375	0.93271068	1	0.76394052
Oct-93	0.53415301	0.95717953	0.86131907	0.72118959
Nov-93	0.24134791	0.97553116	0.66809269	0.4739777
Dic-93	0.05555556	1	0.68235294	0.34944238

## “ANEXO C”

**Tabla A.3.- Datos de la región sur en su estado natural.**

FECHA	DEMANDA	TEMPERATURA	HUMEDAD	POBLACIÓN
Ene-90	289	22.16	81.59	462061
Feb-90	282	22.82	80.46	462600
Mar-90	270	25.3	81.39	463139
Abr-90	296	27.1	79.34	463678
May-90	294	28.18	78.4	464217
Jun-90	310	27.31	79.18	464756
Jul-90	298	27.11	78.94	465295
Ago-90	294	27.32	78.88	465834
Sep-90	293	27.17	78.57	466373
Oct-90	309	26.05	76.21	466912
Nov-90	305	24.42	77.61	467451
Dic-90	300	22.27	80.93	467990
Ene-91	304	22.16	81.59	468529
Feb-91	307	22.82	80.46	469075.66
Mar-91	293	25.3	81.39	469622.33
Abr-91	307	27.1	79.34	470169
May-91	323	28.18	78.4	470715.66
Jun-91	318	27.31	79.18	471262.33
Jul-91	326	27.11	78.94	471809
Ago-91	325	27.32	78.88	472355.66
Sep-91	330	27.17	78.57	472902.33
Oct-91	320	26.05	76.21	473449
Nov-91	321	24.42	77.61	473995.66
Dic-91	321	22.27	80.93	474542.33
Ene-92	318	22.16	81.59	475089
Feb-92	312	22.82	80.46	475643.25
Mar-92	313	25.3	81.39	476197.5
Abr-92	334	27.1	79.34	476751.75
May-92	347	28.18	78.4	477306
Jun-92	353	27.31	79.18	477860.25
Jul-92	362	27.11	78.94	478414.5
Ago-92	342	27.32	78.88	478968.75
Sep-92	355	27.17	78.57	479523
Oct-92	337	26.05	76.21	480077.25
Nov-92	347	24.42	77.61	480631.5
Dic-92	342	22.27	80.93	481185.75
Ene-93	336	22.16	81.59	481740
Feb-93	339	22.82	80.46	482302.03
Mar-93	336	25.3	81.39	482864.06
Abr-93	349	27.1	79.34	483426.09
May-93	364	28.18	78.4	483988.12
Jun-93	366	27.31	79.18	484550.15
Jul-93	404	27.11	78.94	485112.18
Ago-93	362	27.32	78.88	485674.21
Sep-93	383	27.17	78.57	486236.24
Oct-93	357	26.05	76.21	486798.27
Nov-93	378	24.42	77.61	487360.3
Dic-93	368	22.27	80.93	487922.33

## “ANEXO D”

Tabla A.4.- Datos de la región sur estandarizados.

FECHA	DEMANDA	TEMPERATURA	HUMEDAD	POBLACIÓN
Ene-90	0.14179104	0	1	0
Feb-90	0.08955224	0.10963455	0.78996283	0.02084193
Mar-90	0	0.52159468	0.96282528	0.04168386
Abr-90	0.19402985	0.82059801	0.58178439	0.06252579
May-90	0.17910448	1	0.4070632	0.08336772
Jun-90	0.29850746	0.85548173	0.55204461	0.10420964
Jul-90	0.20895522	0.82225914	0.50743494	0.12505157
Ago-90	0.17910448	0.85714286	0.49628253	0.1458935
Sep-90	0.17164179	0.83222591	0.43866171	0.16673543
Oct-90	0.29104478	0.6461794	0	0.18757736
Nov-90	0.26119403	0.37541528	0.26022305	0.20841929
Dic-90	0.2238806	0.01827243	0.87732342	0.22926122
Ene-91	0.25373134	0	1	0.25010315
Feb-91	0.2761194	0.10963455	0.78996283	0.27124127
Mar-91	0.17164179	0.52159468	0.96282528	0.29237978
Abr-91	0.2761194	0.82059801	0.58178439	0.31351829
May-91	0.39552239	1	0.4070632	0.33465642
Jun-91	0.35820896	0.85548173	0.55204461	0.35579493
Jul-91	0.41791045	0.82225914	0.50743494	0.37693344
Ago-91	0.41044776	0.85714286	0.49628253	0.39807156
Sep-91	0.44776119	0.83222591	0.43866171	0.41921007
Oct-91	0.37313433	0.6461794	0	0.44034858
Nov-91	0.38059701	0.37541528	0.26022305	0.46148671
Dic-91	0.38059701	0.01827243	0.87732342	0.48262522
Ene-92	0.35820896	0	1	0.50376373
Feb-92	0.31343284	0.10963455	0.78996283	0.52519534
Mar-92	0.32089552	0.52159468	0.96282528	0.54662695
Abr-92	0.47761194	0.82059801	0.58178439	0.56805856
May-92	0.57462687	1	0.4070632	0.58949018
Jun-92	0.61940299	0.85548173	0.55204461	0.61092179
Jul-92	0.68656716	0.82225914	0.50743494	0.6323534
Ago-92	0.53731343	0.85714286	0.49628253	0.65378501
Sep-92	0.63432836	0.83222591	0.43866171	0.67521663
Oct-92	0.5	0.6461794	0	0.69664824
Nov-92	0.57462687	0.37541528	0.26022305	0.71807985
Dic-92	0.53731343	0.01827243	0.87732342	0.73951146
Ene-93	0.49253731	0	1	0.76094308
Feb-93	0.51492537	0.10963455	0.78996283	0.78267552
Mar-93	0.49253731	0.52159468	0.96282528	0.80440797
Abr-93	0.58955224	0.82059801	0.58178439	0.82614042
May-93	0.70149254	1	0.4070632	0.84787287
Jun-93	0.71641791	0.85548173	0.55204461	0.86960531
Jul-93	1	0.82225914	0.50743494	0.89133776
Ago-93	0.68656716	0.85714286	0.49628253	0.91307021
Sep-93	0.84328358	0.83222591	0.43866171	0.93480266
Oct-93	0.64925373	0.6461794	0	0.9565351
Nov-93	0.80597015	0.37541528	0.26022305	0.97826755
Dic-93	0.73134328	0.01827243	0.87732342	1

## “ANEXO E”

**Tabla A.5.- Datos de la región istmo en su estado natural.**

FECHA	DEMANDA	TEMPERATURA	HUMEDAD	POBLACION
Ene-87	1,500	22.16	81.59	302351
Feb-87	1,480	22.82	80.46	302843.832
Mar-87	1,550	25.3	81.39	303337.468
Abr-87	2,100	27.1	79.34	303831.908
May-87	2,400	28.18	78.4	304327.154
Jun-87	2,450	27.31	79.18	304823.207
Jul-87	2,500	27.11	78.94	305320.069
Ago-87	2,200	27.32	78.88	305817.74
Sep-87	1,900	27.17	78.57	306316.223
Oct-87	1,700	26.05	76.21	306815.519
Nov-87	1,450	24.42	77.61	307315.628
Dic-87	1,550	22.27	80.93	307816.553
Ene-88	1,600	22.16	81.59	308318.294
Feb-88	1,550	22.82	80.46	308820.852
Mar-88	1,400	25.3	81.39	309324.23
Abr-88	1,620	27.1	79.34	309828.429
May-88	1,770	28.18	78.4	310333.449
Jun-88	1,900	27.31	79.18	310839.293
Jul-88	2,300	27.11	78.94	311345.961
Ago-88	2,400	27.32	78.88	311853.455
Sep-88	2,300	27.17	78.57	312361.776
Oct-88	2,000	26.05	76.21	312870.926
Nov-88	1,750	24.42	77.61	313380.905
Dic-88	1,600	22.27	80.93	313891.716
Ene-89	1,600	22.16	81.59	314403.36
Feb-89	1,700	22.82	80.46	314915.837
Mar-89	1,480	25.3	81.39	315429.15
Abr-89	1,500	27.1	79.34	315943.299
May-89	2,100	28.18	78.4	316458.287
Jun-89	2,000	27.31	79.18	316974.114
Jul-89	2,350	27.11	78.94	317490.782
Ago-89	2,400	27.32	78.88	318008.292
Sep-89	2,350	27.17	78.57	318526.645
Oct-89	1,900	26.05	76.21	319045.844
Nov-89	1,900	24.42	77.61	319565.888
Dic-89	1,650	22.27	80.93	320086.781

## “ANEXO F”

**Tabla A.6.- Datos de la región istmo estandarizados.**

FECHA	DEMANDA	TEMPERATURA	HUMEDAD	POBLACION
Ene-87	0.09090909	0	1	0
Feb-87	0.07272727	0.10963455	0.78996283	0.02778745
Mar-87	0.13636364	0.52159468	0.96282528	0.05562019
Abr-87	0.63636364	0.82059801	0.58178439	0.08349831
May-87	0.90909091	1	0.4070632	0.11142186
Jun-87	0.95454545	0.85548173	0.55204461	0.13939093
Jul-87	1	0.82225914	0.50743494	0.16740558
Ago-87	0.72727273	0.85714286	0.49628253	0.19546591
Sep-87	0.45454545	0.83222591	0.43866171	0.22357197
Oct-87	0.27272727	0.6461794	0	0.25172384
Nov-87	0.04545455	0.37541528	0.26022305	0.2799216
Dic-87	0.13636364	0.01827243	0.87732342	0.30816532
Ene-88	0.18181818	0	1	0.33645508
Feb-88	0.13636364	0.10963455	0.78996283	0.36479095
Mar-88	0	0.52159468	0.96282528	0.39317301
Abr-88	0.2	0.82059801	0.58178439	0.42160134
May-88	0.33636364	1	0.4070632	0.450076
Jun-88	0.45454545	0.85548173	0.55204461	0.47859707
Jul-88	0.81818182	0.82225914	0.50743494	0.50716464
Ago-88	0.90909091	0.85714286	0.49628253	0.53577876
Sep-88	0.81818182	0.83222591	0.43866171	0.56443953
Oct-88	0.54545455	0.6461794	0	0.59314702
Nov-88	0.31818182	0.37541528	0.26022305	0.6219013
Dic-88	0.18181818	0.01827243	0.87732342	0.65070245
Ene-89	0.18181818	0	1	0.67955055
Feb-89	0.27272727	0.10963455	0.78996283	0.70844566
Mar-89	0.07272727	0.52159468	0.96282528	0.73738788
Abr-89	0.09090909	0.82059801	0.58178439	0.76637727
May-89	0.63636364	1	0.4070632	0.79541392
Jun-89	0.54545455	0.85548173	0.55204461	0.8244979
Jul-89	0.86363636	0.82225914	0.50743494	0.85362928
Ago-89	0.90909091	0.85714286	0.49628253	0.88280814
Sep-89	0.86363636	0.83222591	0.43866171	0.91203457
Oct-89	0.45454545	0.6461794	0	0.94130864
Nov-89	0.45454545	0.37541528	0.26022305	0.97063042
Dic-89	0.22727273	0.01827243	0.87732342	1

## “ANEXO G”

**Tabla A.7.- Datos de la región arábica en su estado natural.**

Fecha	Demanda	Temperatura	Población	Humedad	Rad_solar
Ago-87	2.2	36	1.8	54	530
Sep-87	2	34	1.8	59	520
Oct-87	1.75	30	1.8	63	480
Nov-87	1.5	24	1.80642	69	380
Dic-87	1.6	18	1.81284	75	330
Ene-88	1.55	15	1.81926	63	350
Feb-88	1.52	16	1.82568	62	400
Mar-88	1.62	21	1.8321	60	420
Abr-88	2.2	27	1.83852	52	500
May-88	2.4	33	1.84494	42	520
Jun-88	2.45	35	1.85136	35	540
Jul-88	2.5	37	1.85778	40	530
Ago-88	2.4	36	1.8642	54	530
Sep-88	2.3	34	1.87062	59	520
Oct-88	2	30	1.87704	63	480
Nov-88	1.8	24	1.88346	69	380
Dic-88	1.6	18	1.88988	75	330
Ene-89	1.6	15	1.8963	63	350
Feb-89	1.55	16	1.90272	62	400
Mar-89	1.4	21	1.90914	60	420
Abr-89	1.65	27	1.91556	52	500
May-89	1.9	33	1.92198	42	520
Jun-89	2	35	1.9284	35	540
Jul-89	2.2	37	1.93482	40	530
Ago-89	2.5	36	1.94124	54	530
Sep-89	2.4	34	1.94766	59	520
Oct-89	2	30	1.95408	63	480
Nov-89	2	24	1.9605	69	380
Dic-89	1.63	18	1.96692	75	330
Ene-90	1.6	15	1.97334	63	350
Feb-90	1.85	16	1.97976	62	400
Mar-90	1.5	21	1.98618	60	420
Abr-90	1.55	27	1.9926	52	500
May-90	2.1	33	1.99902	42	520
Jun-90	2	35	2.00544	35	540
Jul-90	2.5	37	2.01186	40	530
Ago-90	2.6	36	2.01828	54	530
Sep-90	2.4	34	2.0247	59	520
Oct-90	2.5	30	2.03112	63	480
Nov-90	2.2	24	2.03754	69	380
Dic-90	1.9	18	2.04396	75	330
Ene-91	1.8	15	2.05038	63	350
Feb-91	1.6	16	2.0568	62	400
Mar-91	1.5	21	2.06322	60	420
Abr-91	2	27	2.06964	52	500
May-91	1.95	33	2.07606	42	520
Jun-91	1.95	35	2.08248	35	540
Jul-91	2.4	37	2.0889	40	530
Ago-91	2.6	36	2.09532	54	530
Sep-91	2.42	34	2.10174	59	520
Oct-91	2.55	30	2.10816	63	480
Nov-91	2.2	24	2.11458	69	380
Dic-91	1.9	18	2.121	75	330
Ene-92	1.85	15	2.12742	63	350
Feb-92	2.1	16	2.13384	62	400



ANEXOS

Fecha	Demanda	Temperatura	Población	Humedad	Rad_solar
Mar-92	2	21	2.14026	60	420
Abr-92	2.1	27	2.14668	52	500
May-92	2.1	33	2.1531	42	520
Jun-92	2.7	35	2.15952	35	540
Jul-92	2.9	37	2.16594	40	530
Ago-92	3	36	2.17236	54	530
Sep-92	2.7	34	2.17878	59	520
Oct-92	2.3	30	2.1852	63	480
Nov-92	2.25	24	2.19162	69	380
Dic-92	2.2	18	2.19804	75	330
Ene-93	2	15	2.20446	63	350
Feb-93	2.15	16	2.21088	62	400
Mar-93	2.2	21	2.2173	60	420
Abr-93	2.25	27	2.22372	52	500
May-93	2.22	33	2.23014	42	520
Jun-93	2.8	35	2.23656	35	540
Jul-93	2.7	37	2.24298	40	530

“ANEXO H”

**Tabla A.8.- Datos estandarizados de la región arábiga.**

Fecha	Demanda	Temperatura	Población	Humedad	Rad_solar
Ago-87	0.5	0.95454545	0	0.475	0.95238095
Sep-87	0.375	0.86363636	0	0.6	0.9047619
Oct-87	0.21875	0.68181818	0	0.7	0.71428571
Nov-87	0.0625	0.40909091	0.01449275	0.85	0.23809524
Dic-87	0.125	0.13636364	0.02898551	1	0
Ene-88	0.09375	0	0.04347826	0.7	0.0952381
Feb-88	0.075	0.04545455	0.05797101	0.675	0.33333333
Mar-88	0.1375	0.27272727	0.07246377	0.625	0.42857143
Abr-88	0.5	0.54545455	0.08695652	0.425	0.80952381
May-88	0.625	0.81818182	0.10144928	0.175	0.9047619
Jun-88	0.65625	0.90909091	0.11594203	0	1
Jul-88	0.6875	1	0.13043478	0.125	0.95238095
Ago-88	0.625	0.95454545	0.14492754	0.475	0.95238095
Sep-88	0.5625	0.86363636	0.15942029	0.6	0.9047619
Oct-88	0.375	0.68181818	0.17391304	0.7	0.71428571
Nov-88	0.25	0.40909091	0.1884058	0.85	0.23809524
Dic-88	0.125	0.13636364	0.20289855	1	0
Ene-89	0.125	0	0.2173913	0.7	0.0952381
Feb-89	0.09375	0.04545455	0.23188406	0.675	0.33333333
Mar-89	0	0.27272727	0.24637681	0.625	0.42857143
Abr-89	0.15625	0.54545455	0.26086957	0.425	0.80952381
May-89	0.3125	0.81818182	0.27536232	0.175	0.9047619
Jun-89	0.375	0.90909091	0.28985507	0	1
Jul-89	0.5	1	0.30434783	0.125	0.95238095
Ago-89	0.6875	0.95454545	0.31884058	0.475	0.95238095
Sep-89	0.625	0.86363636	0.33333333	0.6	0.9047619
Oct-89	0.375	0.68181818	0.34782609	0.7	0.71428571
Nov-89	0.375	0.40909091	0.36231884	0.85	0.23809524
Dic-89	0.14375	0.13636364	0.37681159	1	0
Ene-90	0.125	0	0.39130435	0.7	0.0952381
Feb-90	0.28125	0.04545455	0.4057971	0.675	0.33333333
Mar-90	0.0625	0.27272727	0.42028986	0.625	0.42857143
Abr-90	0.09375	0.54545455	0.43478261	0.425	0.80952381
May-90	0.4375	0.81818182	0.44927536	0.175	0.9047619
Jun-90	0.375	0.90909091	0.46376812	0	1
Jul-90	0.6875	1	0.47826087	0.125	0.95238095

## ANEXOS

Fecha	Demanda	Temperatura	Población	Humedad	Rad_solar
Ago-90	0.75	0.95454545	0.49275362	0.475	0.95238095
Sep-90	0.625	0.86363636	0.50724638	0.6	0.9047619
Oct-90	0.6875	0.68181818	0.52173913	0.7	0.71428571
Nov-90	0.5	0.40909091	0.53623188	0.85	0.23809524
Dic-90	0.3125	0.13636364	0.55072464	1	0
Ene-91	0.25	0	0.56521739	0.7	0.0952381
Feb-91	0.125	0.04545455	0.57971014	0.675	0.33333333
Mar-91	0.0625	0.27272727	0.5942029	0.625	0.42857143
Abr-91	0.375	0.54545455	0.60869565	0.425	0.80952381
May-91	0.34375	0.81818182	0.62318841	0.175	0.9047619
Jun-91	0.34375	0.90909091	0.63768116	0	1
Jul-91	0.625	1	0.65217391	0.125	0.95238095
Ago-91	0.75	0.95454545	0.66666667	0.475	0.95238095
Sep-91	0.6375	0.86363636	0.68115942	0.6	0.9047619
Oct-91	0.71875	0.68181818	0.69565217	0.7	0.71428571
Nov-91	0.5	0.40909091	0.71014493	0.85	0.23809524
Dic-91	0.3125	0.13636364	0.72463768	1	0
Ene-92	0.28125	0	0.73913043	0.7	0.0952381
Feb-92	0.4375	0.04545455	0.75362319	0.675	0.33333333
Mar-92	0.375	0.27272727	0.76811594	0.625	0.42857143
Abr-92	0.4375	0.54545455	0.7826087	0.425	0.80952381
May-92	0.4375	0.81818182	0.79710145	0.175	0.9047619
Jun-92	0.8125	0.90909091	0.8115942	0	1
Jul-92	0.9375	1	0.82608696	0.125	0.95238095
Ago-92	1	0.95454545	0.84057971	0.475	0.95238095
Sep-92	0.8125	0.86363636	0.85507246	0.6	0.9047619
Oct-92	0.5625	0.68181818	0.86956522	0.7	0.71428571
Nov-92	0.53125	0.40909091	0.88405797	0.85	0.23809524
Dic-92	0.5	0.13636364	0.89855072	1	0
Ene-93	0.375	0	0.91304348	0.7	0.0952381
Feb-93	0.46875	0.04545455	0.92753623	0.675	0.33333333
Mar-93	0.5	0.27272727	0.94202899	0.625	0.42857143
Abr-93	0.53125	0.54545455	0.95652174	0.425	0.80952381
May-93	0.5125	0.81818182	0.97101449	0.175	0.9047619
Jun-93	0.875	0.90909091	0.98550725	0	1
Jul-93	0.8125	1	1	0.125	0.95238095

## “ANEXO I”

Tabla A.9. Análisis de datos de la región norte.

CONCEPTO	TEMPERATURA	HUMEDAD	POBLACIÓN	DEMANDA
Media	16.6816	49.9725	1721463.185	881.7708
Mediana	17.305	51.785	1721230.906	869
Moda	5.35	50.09	S/M	712
Desviación estándar	7.7166	8.3994	48362.1290	128.1269
Varianza de la muestra	59.5474	70.5505	2338895526	16416.5208
Curtois o afilamiento	-1.5027	-0.9135	-1.1723	-0.5951
Coficiente de asimetría	-0.0787	-0.3714	-0.0078	0.3348
Rango	21.96	28.05	163473.2	538
Mínimo	5.35	34.74	1639526.8	662
Máximo	27.31	62.79	1803000	1200
Suma	800.72	2398.68	82630232.87	42325
Elementos	48	48	48	48
Correlación con la Demanda	0.7809	0.4196	0.5879	1

## “ANEXO J”

**Tabla A.10.- Análisis de datos de la región sur.**

CONCEPTO	TEMPERATURA	HUMEDAD	POBLACIÓN	DEMANDA
Media	25.6008	79.2916	474882.4258	327.8958
Mediana	26.575	79.06	474815.665	324
Moda	22.16	81.59	S/M	294
Desviación estándar	2.1010	1.5349	7702.6678	29.2081
Varianza de la muestra	4.4144	2.3559	59331091.5	853.1165
Curtosis o afilamiento	-1.2023	-0.4926	-1.1994	-0.2864
Coefficiente de asimetría	-0.6020	-0.1927	0.0198	0.3676
Rango	6.02	5.38	25861.33	134
Mínimo	22.16	76.21	462061	270
Máximo	28.18	81.59	487922.33	404
Suma	1228.84	3806	22794356.44	15739
Elementos	48	48	48	48
Correlación con la Demanda	0.2167	-0.2840	0.9156	1

## “ANEXO K”

**Tabla A.11.- Análisis de datos de la región istmo.**

	DEMANDA	TEMPERATURA	HUMEDAD	POBLACION
Media	1886.11111	25.6008333	79.2916667	311137.052
Error típico	58.7141012	0.35142462	0.25673298	889.78149
Mediana	1835	26.575	79.06	311092.627
Moda	1900	22.16	81.59	#N/A
Desviación estándar	352.284607	2.10854774	1.54039791	5338.68894
Varianza de la muestra	124104.444	4.44597357	2.37282571	28501599.6
Curtosis	-1.34141065	-1.20146079	-0.46522755	-1.19948336
Coefficiente de asimetría	0.36855463	-0.60872236	-0.19488681	0.02114697
Rango	1100	6.02	5.38	17735.7807
Mínimo	1400	22.16	76.21	302351
Máximo	2500	28.18	81.59	320086.781
Suma	67900	921.63	2854.5	11200933.9
Correlación con la Demanda	1	0.68466432	-0.44839392	0.10018007

## “ANEXO L”

**Tabla A.12.- Análisis de datos de la región arábiga.**

	TEMPERATURA	HUMEDAD	RAD_SOLAR	POBLACIÓN	DEMANDA
Media	27.1666	56.1666	458.3333	2.0153	2.0876
Mediana	28.5	59.5	490	2.0150	2.1
Moda	36	63	530	1.8	2
Desviación estándar	7.8525	11.6340	74.6635	0.1339	0.3870
Varianza de la muestra	61.6619	135.3521	5574.6478	0.0179	0.1498
Curtosis	-1.4700	-0.7800	-1.3858	-1.2136	-0.6899
Coefficiente de asimetría	-0.2816	-0.3822	-0.4778	0.0107	0.1704
Rango	22	40	210	0.4429	1.6
Mínimo	15	35	330	1.8	1.4
Máximo	37	75	540	2.2429	3
Suma	1956	4044	33000	145.1043	150.31
Cuenta	72	72	72	72	72
Correlación	0.7080	-0.4420	0.6237	0.4486	1

# APÉNDICES

“APÉNDICE A”

**Programa 1.- Regresión Lineal.**

```

PROGRAM rg_ln_M
USE MSIMSL
!*****
!
!PROGRAMA DESARROLLADO POR GABRIEL ALLENDE SANCHO
!
!*****
!
!ESTE PROGRAMA CALCULA LA ECUACIÓN REGRESIVA MULTIVARIABLE DE UNA SERIE
!-----
IMPLICIT NONE
INTEGER::n,m,i,j,k,l
!SE DEFINEN LAS MATRICES DINAMICAS
REAL,DIMENSION(:),ALLOCATABLE::y,ycalc,sx,sxx,sxy,se,ec,P
REAL,DIMENSION(:,),ALLOCATABLE::x,sxi,me,xm,xm1,xp,xpm
REAL::sy,syy
!
! SE DEFINEN LAS VARIABLES PARA LOS ARCHIVOS
CHARACTER vecty_dat*15,matxp_dat*15,matripp_dat*15
CHARACTER matx_dat*15,vectp_dat*15,prono_dat*15
! PIDE LOS PARAMETROS DE VARIABLES Y UNIDADES
PRINT*, 'DAME EL NÚMERO DE PERIODOS DE LA DEMANDA'
READ*,m
PRINT*, 'DAME EL NUMERO DE VARIABLES INDEPENDIENTES'
read*,n
PRINT*, 'DAME EL NUMERO DE pronosticos'
read*,l
! SE ASIGNAN VALORES DE LA DIMENSION A LAS MATRICES
ALLOCATE(x(n,m))
ALLOCATE(xp(n,l))
ALLOCATE(xpm(n+1,l))
ALLOCATE(sxi(n,n))
ALLOCATE(me(n+1,n+1))
ALLOCATE(xm(n+1,m))
ALLOCATE(xm1(m,n+1))
ALLOCATE(y(m))
ALLOCATE(sxy(n))
ALLOCATE(se(n+1))
ALLOCATE(P(l))
ALLOCATE(ec(n+1))
ALLOCATE(sx(n))
ALLOCATE(sxx(n))
ALLOCATE(ycalc(m))
! ENTRADA DE DATOS DE LA MATRIZ "x"
print*, 'DE EL NOMBRE DEL ARCHIVO DE LA MATRIZ X (VARIABLE INDEPENDIENTE) '
READ(*, '(a)') matx_dat
OPEN(unit=1,file=matx_dat)
READ(1,*) ((x(J,K),J=1,n),K=1,m)
CLOSE(unit=1)
!OPCIONAL SI SE QUIERE VER LA MATRIZ DE VARIABLES QUITAR EL COMENTARI
!PRINT*, ' MATRIZ DE VARIABLES '

```

```

!PRINT'(3F10.2)',x
!ENTRADA DE DATOS DE LOS VECTORES "y"
print*,'DE EL NOMBRE DEL ARCHIVO DEL VECTOR Y (VARIABLE DEPENDIENTE) '
READ(*, '(a)') vecty_dat
OPEN(unit=1,file=vecty_dat)
READ(1,*) (y(J),J=1,m)
CLOSE(unit=1)
!OPCIONAL SI SE QUIERE VER LA MATRIZ DE VARIABLES QUITAR EL COMENTARI
!PRINT*,' MATRIZ DE VARIABLES DEPENDIENTES'
!PRINT'(F10.2)',y
!ENTRADA DE DATOS DE LA MATRIZ "xp"
print*,'DE EL NOMBRE DEL ARCHIVO DE LA MATRIZ XP (VARIABLE PROYECTADA'
READ(*, '(a)') matxp_dat
OPEN(unit=1,file=matxp_dat)
READ(1,*) ((xp(J,K),J=1,n),K=1,1)
CLOSE(unit=1)
!OPCIONAL SI SE QUIERE VER LA MATRIZ DE VARIABLES QUITAR EL COMENTARI
!PRINT*,' MATRIZ DE VARIABLES PROYECTADAS'
!PRINT'(3F10.2)',xp
!SE CALCULA LA SY=SUMA DE (Y), Y SE REALIZAN LAS SUMAS DE SX1,...,SXn
sy=0
do i=1,m
    sy=sy+y(i)
end do
se(1)=sy
do i=1,n
    sx(i)=0
end do
do i=1,n
    do j=1,m
        sx(i)=sx(i)+x(i,j)
    end do
end do
do i=1,n+1
    do j=1,n+1
        me(i,j)=0
    end do
end do
!SE ASIGNAN VALORES A LA COLUMNA,1 Y RENGLON,1 DE LA MATRIZ DE ECUACI
do i=1,n
    me(1,i+1)=sx(i)
    me(i+1,1)=sx(i)
end do
PRINT*,'suma de Y y suma Xi'
PRINT'(F10.2)',sy
PRINT'(3F10.2)',sx
!SE CALCULAN LA SUMA DE LOS CUADRADOS
syy=0
do i=1,m
    syy=syy+y(i)*y(i)
end do
do i=1,n
    sxx(i)=0
end do
do i=1,n
    do j=1,m

```

```

                sxx(i)=sxx(i)+x(i,j)*x(i,j)
            end do
            me(i+1,i+1)=sxx(i)
        end do
        !
        PRINT*,'suma de YY y suma XXi'
        PRINT'(F14.2)',syy
        PRINT'(3F10.2)',sxx
        !SE CALCULAN LA SUMA DE X1*Y,X2*Y,..Xn*Y
        do i=1,m
            sxy(i)=0
        end do
        do i=1,n
            do j=1,m
                sxy(i)=sxy(i)+y(j)*x(i,j)
            end do
            se(1)=sy
            se(i+1)=sxy(i)
        end do
        !
        PRINT*,'suma de YXi '
        PRINT'(1F10.2)',sxy
        !SE CALCULAN LA SUMA DE X1*X2,X1*X3,..Xn-1*Xn
        do i=1,n
            do j=1,n
                sxi(i,j)=0
            end do
        end do
        do i=1,n-1
            do j=i+1,n
                do k=1,m
                    sxi(i,j)=sxi(i,j)+x(i,k)*x(j,k)
                    sxi(j,i)=sxi(i,j)
                end do
                me(i+1,j+1)=sxi(i,j)
                me(j+1,i+1)=sxi(i,j)
            end do
        end do
        PRINT*,'suma de XiXi+1 '
        PRINT'(3F10.2)',sxi
        me(1,1)=m
        !-----*****-----
        !OPCIONAL
        !print*,'LA MATRIZ DE ECUACIONES SIMULTANES ES'
        !PRINT'(4F10.2)',me
        !print*,'LA igualdad de la MATRIZ DE ECUACIONES SIMULTANES ES'
        !PRINT'(4F10.2)',se
        !-----*****-----
        call lsarg(n+1,me,n+1,se,1,ec)
        print*,'LA solución de la MATRIZ DE ECUACIONES SIMULTANES ES'
        PRINT'(4F10.2)',ec
        !
        do i=1,n
            do j=1,m
                xm(i,j)=0
            end do
        end do
    
```



```

end do
!
do i=1,m
    xm(1,i)=1
end do
do i=1,n
    do j=1,m
        xm(i+1,j)=x(i,j)
    end do
end do
PRINT*, 'MATRIZ DE VARIABLES expandida'
PRINT' (4F10.2)', xm

PRINT*, ' AJUSTE DE LA CURVA '
ycalc=matmul(ec,xm)
PRINT' (F10.2)', ycalc
do i=1,l
    xpm(1,i)=1
end do
do i=1,n
    do j=1,l
        xpm(i+1,j)=xp(i,j)
    end do
end do
print*, 'MATRIZ PROYECTADA EXPANDIDA'
PRINT' (4F10.2)', xpm
!CALCULO DEL PRONÓSTICO
p=matmul(ec,xpm)
print*, 'CALCULO DEL PRONÓSTICO'
PRINT' (F10.2)', p
!-----*****-----
! GRABA DATOS EN ARCHIVO
print*, 'DAME EL NOMBRE DEL ARCHIVO PARA GRABAR PRONÓSTICO '
READ(*, '(a)') prono_dat
OPEN(unit=4,file=prono_dat)
!-----*****-----
do j=1,n+1
write(4, '(1F14.10)') ec(j)
end do
WRITE(4,*)
!-----*****-----
DO J=1,m
WRITE(4, '(1F14.10)') ycalc(J)
end do
WRITE(4,*)
!-----*****-----
DO J=1,l
WRITE(4, '(1F14.10)') p(J)
end do
CLOSE(unit=4)
END          PROGRAM rg_ln_M

```

“APÉNDICE B”

**Programa 2.- VAR.**

```

PROGRAM var_uni
use msimsl
!*****
!PROGRAMA DESARROLLADO POR GABRIEL ALLENDE SANCHO
!*****
!-----
! se requiere preparar tres matrices en archivos individuales
! LA MATRIZ VARIABLES:=A(n,m) n variables m periodos de cada variable
! LA MATRIZ DE DEMANDA:=V(m) m periodos de la demanda
! LA MATRIZ VARIABLES PROYECTADAS:= E(n,l) l variables proyectadas
!
! los resultados se dan en un archivo con los valores del ajuste y
! el pronóstico para las variables proyectadas
!-----
!
! SE DEFINEN LAS MATRICES DINAMICAS
REAL,DIMENSION(:, ),ALLOCATABLE::A,B,C,E,In
REAL,DIMENSION(:, ),ALLOCATABLE::factor
integer,DIMENSION(:),ALLOCATABLE::ipvt
REAL,DIMENSION(:),ALLOCATABLE::rj,h,x,res
REAL,DIMENSION(:),ALLOCATABLE::D,P,V,F
!
! SE DEFINEN LAS VARIABLES PARA LOS ARCHIVOS
CHARACTER matrizA_dat*15
CHARACTER matrizV_dat*15
CHARACTER matrizE_dat*15
CHARACTER matrizP_dat*15
!
! SE DEFINEN OTRAS VARIABLES
integer::ipath,lda,ldfac
!integer::itmax=50
real::recond !t
!
!-----
! PIDE LOS PARAMETROS DE VARIABLES Y UNIDADES
PRINT*,'DAME EL NÚMERO DE VARIABLES CONTANDO LA DEMANDA'
READ*,n
PRINT*,'DAME EL NÚMERO DE PERIODOS A ANALIZAR'
read*,m
!
!-----
! SE ASIGNAN VALORES DE LA DIMENSION A LAS MATRICES
ALLOCATE(A(n,m))
ALLOCATE(B(m,n))
ALLOCATE(C(n,n))
ALLOCATE(In(n,n))
ALLOCATE(factor(n,m))
ALLOCATE(D(n))
ALLOCATE(P(n))
ALLOCATE(V(m))
ALLOCATE(ipvt(n))

```

```

ALLOCATE(rj(n))
ALLOCATE(h(m))
ALLOCATE(x(n))
ALLOCATE(res(n))
!
!-----
! ENTRADA DE DATOS DE LA MATRIZ VARIABLES "A"
print*, 'DE EL NOMBRE DEL ARCHIVO DE LA MATRIZ DE VARIABLES '
READ(*, '(a)') matrizA_dat
OPEN(unit=1,file=matrizA_dat)
READ(1,*) ((A(J,K),J=1,n),K=1,m)
CLOSE(unit=1)
!OPCIONAL SI SE QUIERE VER LA MATRIZ DE VARIABLES QUITAR EL COMENTARI
!PRINT*, ' MATRIZ DE VARIABLES '
!PRINT'(4F10.6)', A
!
!-----
! TRANSPUESTA DE A
B=transpose(A)
!OPCIONAL SI SE QUIERE VER LA TRANSPUESTA QUITAR EL COMENTARIO SIGUI
!PRINT*, ' MATRIZ TRANSPUESTA '
!PRINT'(42F10.2)', B
!
!-----
! MULTIPLICACIÓN DE LA MATRIZ TRANSPUESTA B*A=C
C=MATMUL(A,B)
!OPCIONAL SI SE QUIERE VER ESTA MATRIZ QUITAR EL COMENTARIO SIGUI
!PRINT*, ' MATRIZ TRANS*A '
!PRINT'(4F10.2)', C
!
!-----
! CALCULA LA INVERSA DE C
ipath=1
lda=n
ldfac=n
call lfcrg(n,C,lda,factor,ldfac,ipvt,recond)
do q=1,n
    rj(q)=0
end do
do j=1,n
    rj(j)=1
    call lfirg(n,C,lda,factor,ldfac,ipvt,rj,ipath,In(1,j),res)
    rj(j)=0
end do
!OPCIONAL SI SE QUIERE VER LA INVERSA QUITAR EL COMENTARIO SIGUI
!PRINT*, 'MATRIZ INVERSA '
!PRINT'(4F10.2)', In
!
!-----
! ENTRADA DE DATOS DE LA MATRIZ DE LA DEMANDA "V"
print*, 'DE EL NOMBRE DEL ARCHIVO DE LA MATRIZ DE LA DEMANDA '
READ(*, '(a)') matrizV_dat
OPEN(unit=1,file=matrizV_dat)
READ(1,*) (V(K),K=1,m)
CLOSE(unit=1)
!OPCIONAL SI SE QUIERE VER LA MATRIZ DE DEMANDA QUITE EL COMENTARIO

```

```

!PRINT*, ' MATRIZ DE VALORES HISTORICOS DE LA DEMANDA '
!PRINT '(42F10.2)', V
!
!-----
! MULTIPLICA LA MATRIZ TRANSPUESTA POR V
D=MATMUL(A,V)
!OPCIONAL SI SE QUIERE VER ESTA MATRIZ QUITAR EL COMENTARIO SIGUI
!PRINT*, ' MATRIZ TRANS*V'
!PRINT '(4F10.2)', D
!
!-----
! MULTIPLICA LA MATRIZ INVERSA POR D CALCULA PARAMETROS
PRINT*, ' LOS PARAMETROS DE AJUSTE DE LA ECUACIÓN SON: '
PRINT*, '      B      Ao      A1      A2'
P=MATMUL(D,In)
PRINT '(4F10.4)', P
!
!-----
!REALIZA AJUSTE DE LA CURVA
PRINT*, ' AJUSTE DE LA CURVA '
h=MATMUL(P,A)
PRINT '(1F10.4)', h
!
!-----
!REALIZA EL "PRONÓSTICO"
PRINT*, 'DAME EL NÚMERO DE PERIODOS A PRONOSTICAR '
read*, l
ALLOCATE(E(n,l))
ALLOCATE(F(l))
! ENTRADA DE DATOS DE LA MATRIZ VARIABLES PROYECTADAS"E"
print*, 'EL NOMBRE DEL ARCHIVO DE LA MATRIZ DE VARIABLES PROYECTADAS'
READ(*, '(a)') matrizE_dat
OPEN(unit=1,file=matrizE_dat)
READ(1,*) ((E(J,K),J=1,n),K=1,l)
CLOSE(unit=1)
!PRINT '(4F10.4)', E
! GRABA DATOS EN ARCHIVO
print*, 'DAME EL NOMBRE DEL ARCHIVO PARA GRABAR PRONÓSTICO '
READ(*, '(a)') matrizP_dat
OPEN(unit=4,file=matrizP_dat)
do j=1,n+1
write(4,'(1F14.10)') P(j)
end do
WRITE(4,*)
DO J=1,m
WRITE(4,'(1F10.4)') h(J)
end do
WRITE(4,*)
!REALIZA PRONÓSTICO DE VALORES
F=MATMUL(P,E)
DO J=1,l
WRITE(4,'(1F10.4)') F(J)
end do
CLOSE(unit=4)
!PRINT '(1F10.4)', F
end program var_uni

```

“APÉNDICE C”

**Programa 3.- Redes Neuronales.**

```

!
!*****
!PROGRAMA DE UNA R.N CON EL MODELO DE RETROPROPAGACIÓN!!
!PROGRAMA DESARROLLADO POR GABRIEL ALLENDE SANCHO'
!*****
WRITE(*,'(4X,a)')'INSTITUTO POLITECNICO NACIONAL'
WRITE(*,'(4X,a)')'E.S.I.M.E. - S.E.P.I'
WRITE(*,'(4X,a)')'R.N, ALGORITMO DE RETROPROPAGACION'
WRITE(*,'(4X,a)')'
WRITE(*,*)

USE MSIMSLMS
IMPLICIT NONE
double precision, DIMENSION(:), ALLOCATABLE ::y
double precision, DIMENSION(:,:), ALLOCATABLE ::xd,v,wh,net,ye,ys,vh
double precision, DIMENSION(:,:), ALLOCATABLE ::e,yd,yp,s,dw,xt,wo,hp
double precision, DIMENSION(:,:), ALLOCATABLE ::vht,teh,vhh,nth,he,yh
double precision, DIMENSION(:,:), ALLOCATABLE ::yht,dwh,sh,vi,ie,nti
double precision, DIMENSION(:,:), ALLOCATABLE ::yi,ip,yit,wi,ssi,teia
double precision, DIMENSION(:,:), ALLOCATABLE ::dwi,sip,shp,tei,mti
double precision, DIMENSION(:,:), ALLOCATABLE ::woa,wha,wia,mo,mi,mh
double precision, DIMENSION(:,:), ALLOCATABLE ::mth,teha,sipt
CHARACTER archiv_ent*15,prono_dat*15
INTEGER i,j,n,m,h,k,t,f
INTEGER b,g
double precision::fa,vm,tm,teta,tetaa,mte,tol,to,se,pe,syd,vae
WRITE(*,'(4X,a\)' )'NUMERO DE VALORES PARA EL ENTRENAMIENTO:'
READ(*,*) m
WRITE(*,'(4X,a\)' )'          NUMERO DE VARIABLES EN LA ENTRADA:'
READ(*,*) n
WRITE(*,'(4X,a\)' )'          NUMERO DE NEURONAS EN LA CAPA OCULTA:'
READ(*,*) h
WRITE(*,'(4X,a\)' )'          NUMERO DE ITERACIONES:'
READ(*,*) t
WRITE(*,'(4X,a\)' )'          FACTOR DE APRENDIZAJE:'
READ(*,*) fa
WRITE(*,'(4X,a\)' )'          VALOR DE LA TEMPERATURA:'
READ(*,*) tm
WRITE(*,'(4X,a\)' )'          MOMENTO:'
READ(*,*) vm
WRITE(*,'(4X,a\)' )'          TOLERANCIA:'
READ(*,*) tol
g=1
ALLOCATE( wi(h,n) )
ALLOCATE( wia(h,n) )
ALLOCATE( mi(h,n) )
ALLOCATE( dwi(h,n) )
ALLOCATE( vi(h,m) )
ALLOCATE( ie(h,m) )
ALLOCATE( nti(h,m) )
ALLOCATE( yi(h,m) )
ALLOCATE( ip(h,m) )

```

```

ALLOCATE( yit(m,h) )
ALLOCATE( tei(1,h) )
ALLOCATE( teia(1,h) )
ALLOCATE( mti(1,h) )
ALLOCATE( ssi(h,m) )
ALLOCATE( sip(h,m) )
ALLOCATE( sipt(m,h) )
ALLOCATE( xd(n,m) )
ALLOCATE( vh(n,m) )
ALLOCATE( vhh(n,m) )
ALLOCATE( nth(n,m) )
ALLOCATE( he(n,m) )
ALLOCATE( yh(n,m) )
ALLOCATE( hp(n,m) )
ALLOCATE( wo(1,h) )
ALLOCATE( woa(1,h) )
ALLOCATE( mo(1,h) )
ALLOCATE( dw(1,h) )
ALLOCATE( yht(m,n) )
ALLOCATE( xt(m,n) )
ALLOCATE( vht(m,n) )
ALLOCATE( v(1,m) )
ALLOCATE( wh(1,n) )
ALLOCATE( wha(1,n) )
ALLOCATE( mh(1,n) )
ALLOCATE( teh(1,n) )
ALLOCATE( mth(1,n) )
ALLOCATE( teha(1,n) )
ALLOCATE( net(1,m) )
ALLOCATE( yd(1,m) )
ALLOCATE( ys(1,m) )
ALLOCATE( y(m) )
ALLOCATE( ye(1,m) )
ALLOCATE( yp(1,m) )
ALLOCATE( e(1,m) )
ALLOCATE( s(1,m) )
ALLOCATE( sh(n,m) )
ALLOCATE( shp(n,m) )
ALLOCATE( dwh(1,n) )
WRITE(*, '(4X,a\)' ) '¿LA RED ESTA ENTRENADA..SI=1,..NO=0...?'
READ(*, *)B
IF(B.EQ.1)THEN
!-----
WRITE(*, '(4X,a\)' ) ' DAME EL ARCHIVO DE DATOS DE LA MATRIZ WH:'
READ(*, '(a)') archiv_ent
OPEN(unit=1,file=archiv_ent)
READ(1,*) ((wh(i,j),i=1,1),j=1,n)
CLOSE(unit=1)
!-----
WRITE(*, '(4X,a\)' ) ' DAME EL ARCHIVO DE DATOS DE LA MATRIZ WI:'
READ(*, '(a)') archiv_ent
OPEN(unit=1,file=archiv_ent)
READ(1,*) ((wi(i,j),i=1,h),j=1,n)
CLOSE(unit=1)
!-----
WRITE(*, '(4X,a\)' ) ' DAME EL ARCHIVO DE DATOS DE LA MATRIZ WO:'

```

```

READ(*, '(a)') archiv_ent
OPEN(unit=1,file=archiv_ent)
READ(1,*) ((wo(i,j),i=1,1),j=1,h)
CLOSE(unit=1)
!-----
WRITE(*,'(4X,a\)' )' DAME EL ARCHIVO DE LA MATRIZ TETA ENTRADA:'
READ(*, '(a)') archiv_ent
OPEN(unit=1,file=archiv_ent)
READ(1,*) ((teh(i,j),i=1,1),j=1,n)
CLOSE(unit=1)
!-----
WRITE(*,'(4X,a\)' )' DAME EL ARCHIVO DE LA MATRIZ TETA OCULTA:'
READ(*, '(a)') archiv_ent
OPEN(unit=1,file=archiv_ent)
READ(1,*) ((tei(i,j),i=1,1),j=1,h)
CLOSE(unit=1)
!-----
WRITE(*,'(4X,a\)' )'          DAME EL VALOR DE LA TETA DE SALIDA:'
READ(*,*) teta
!-----
ELSE
do i=1,n
    wh(1,i)=0.0000000001*wo(1,i)
    wha(1,i)=0
    teh(1,i)=0.000000000001*i
    teha(1,i)=0
    do j=1,h
        wo(1,j)=0.000000001*j
        woa(1,j)=0
        tei(1,j)=teh(1,j)
        teia(1,j)=0
        wi(j,i)=0.000000000001*i*j
        wia(j,i)=0
    end do
end do
teta=wo(1,4)
tetaa=0
END IF
!-----
WRITE(*,'(4X,a\)' )'          DAME EL ARCHIVO DE DATOS DE ENTRADA:'
READ(*, '(a)') archiv_ent
OPEN(unit=3,file=archiv_ent)
READ(3,*) ((xd(i,j),i=1,n),j=1,m)
CLOSE(unit=3)
!-----
WRITE(*,'(4X,a\)' )'DAME EL ARCHIVO DE DATOS DE SALIDA DESEADA:'
READ(*, '(a)') archiv_ent
OPEN(unit=4,file=archiv_ent)
READ(4,*) ((yd(i,j),i=1,1),j=1,m)
CLOSE(unit=4)
!-----
do i=1,m
    net(1,i)=0
    nth(1,i)=0
end do
do i=1,n

```

```

                dw(1,i)=0
                dwh(1,i)=0
end do
300 continue
do k=1,t
    print '(I8)',k
    !***** capa de entrada
    xt=transpose(xd)
    do i=1,m
        do j=1,n
            vhh(j,i)=wh(1,j)*xd(j,i)
        end do
    end do
    do i=1,m
        do j=1,n
            nth(j,i)=(vhh(j,i)-teh(1,j))/(-tm)
        end do
    end do
    he=exp(nth)
    yh=1/(1+he) !esta es la salida de la capa
    hp=yh*(1-yh) ! esta es f prima
    !***** capa intermedia
    yht=transpose(yh)
    vi=matmul(wi,yh)
    do i=1,m
        do j=1,h
            nti(j,i)=(vi(j,i)-tei(1,j))/(-tm)
        end do
    end do
    ie=exp(nti)
    yi=1/(1+ie) !esta es la salida de la capa
    ip=yi*(1-yi) ! esta es f prima
    !***** capa de salida
    yit=transpose(yi)
    v=matmul(wo,yi)
    net=(v-teta)/(-tm)
    ye=exp(net)
    ys=1/(1+ye)
    e=yd-ys
    !*****
    se=0
    syd=0
    do i=1,m
        vae=abs(e(1,i))
        se=se+vae
        syd=syd+yd(1,i)
    end do
    pe=100*(se/syd)
    !*****
    if (g.eq.2)goto 400
    f=0
    do i=1,m
        to=dabs(e(1,i))
        if (to<tol) then
            f=f+1
        else

```



```

                goto 100
            end if
        end do
        100      continue
        if(f.eq.m)goto 200
        !***** capa de salida
        yp=ys*(1-ys)      !esta es la f prima de la salida
        s=fa*(e*yp)       !esta es la señal de error
        dw=matmul(s,yit)  !este es el incremento de los pesos
        do i=1,m
                                !
                do j=1,h
                                !!
                    ssi(j,i)=s(1,i)*wo(1,j)  !!!para la capa intermedia
                end do
                                !!
        end do
                                !
        mo=vm*(wo-woa)
        woa=wo
        wo=wo+dw+mo
        mte=vm*(teta-tetaa)
        tetaa=teta
        do i=1,m
                teta=-teta+s(1,i)
        end do
        teta=teta+mte
        !***** capa intermedia
        do i=1,m
                do j=1,h
                    sip(j,i)=ssi(j,i)*ip(j,i)
                end do
        end do
        dwi=matmul(sip,yht)
        sipt=transpose(sip)
        sh=matmul(sipt,wi)      !!!para la capa de entrada
        mi=vm*(wi-wia)
        wia=wi
        wi=wi+dwi+mi
        mti=vm*(tei-teia)
        teia=tei
        do i=1,h
                do j=1,m
                    tei(1,i)=-tei(1,i)+sip(i,j)
                end do
        end do
        tei=tei+mti
        !***** capa de entrada
        do i=1,m
                do j=1,n
                    shp(j,i)=sh(j,i)*hp(j,i)
                end do
        end do
        do i=1,n
                do j=1,m
                    dwh(1,i)=dwh(1,i)+shp(i,j)*xd(i,j)
                end do
        end do
        mh=vm*(wh-wha)
        wha=wh
    
```

```

wh=wh+dwh+mh
mth=vm*(teh-teha)
teha=teh
do i=1,n
    do j=1,m
        teh(1,i)=-teh(1,i)+shp(i,j)
    end do
end do
teh=teh+mth
!*****TERMINA EL CALCULO DE LOS PESOS
end do !de la k
200     continue

PRINT*,' REAL          AJUSTE          ERROR          SEÑAL'
do i=1,m
    print'(5F14.10)',yd(1,i),ys(1,i),e(1,i),s(1,i)
end do
PRINT*,' ***** wo *****'
print'(4F12.8)',wo
PRINT*,' ***** wi *****'
print'(4F16.12)',wi
PRINT*,' ***** wh *****'
print'(3F16.12)',wh
PRINT*,' ***** teta *****'
print'(1F12.8)',teta
PRINT*,' ***** tetah *****'
print'(3F12.8)',teh
PRINT*,' ***** tei *****'
print'(4F12.8)',tei
PRINT*,'valores  variables iteraciones'
print'(3I10.7)',m,n,k
PRINT*,'aprendizaje temperatura momento tolerancia'
print'(4F10.7)',fa,tm,vm,tol
PRINT*,' ***** suma del error *****'
print'(1F12.8)',se
PRINT*,' ***** error porcentual *****'
print'(1F12.8)',pe
!*****
WRITE(*,'(4X,a)')'CALCULOS FINALIZADOS'
! GRABA DATOS EN ARCHIVO
print*,'DESEA GUARDAR LOS RESULTADOS DEL AJUSTE DE EL ARCHIVO'
READ(*,'(a)') prono_dat
OPEN(unit=4,file=prono_dat)
WRITE(4,'(2x,a,I8)')'          ITERACION : ',k
WRITE(4,*)
WRITE(4,'(2x,a,f10.6)')'FACTOR APRENDIZAJE: ',fa
WRITE(4,*)
WRITE(4,'(2x,a,F10.6)')'          TEMPERATURA : ',tm
WRITE(4,*)
WRITE(4,'(2x,a,F10.6)')'          MOMENTO : ',vm
WRITE(4,*)
WRITE(4,'(2x,a,F10.6)')'          TOLERANCIA : ',tol
WRITE(4,*)
WRITE(4,'(2x,a,F10.6)')' ERROR ABSOLUTO: ',se
WRITE(4,*)
WRITE(4,'(2x,a,F10.6)')' ERROR PORCENTULA: ',pe

```

```

WRITE(4,*)
WRITE(4,'(2x,a,F14.8)')'          TETA : ',teta
WRITE(4,*)
!-----
WRITE(4,*)'  MATRIZ DE PESOS TETA H: '
do j=1,n
write(4,'(1F14.8)') teh(1,j)
end do
WRITE(4,*)
!-----
WRITE(4,*)'  MATRIZ DE PESOS TETA I: '
do j=1,h
write(4,'(1F14.8)') tei(1,j)
end do
WRITE(4,*)
!-----
WRITE(4,*)'  MATRIZ DE PESOS WO: '
do j=1,h
write(4,'(1F14.8)') wo(1,j)
end do
WRITE(4,*)
!-----
WRITE(4,*)'  MATRIZ DE PESOS WI: '
do j=1,h
      do i=1,n
        write(4,'(1F14.8)') wi(j,i)
      end do
end do
WRITE(4,*)
!-----
WRITE(4,*)'  MATRIZ DE PESOS WH: '
do j=1,n
write(4,'(1F14.8)') wh(1,j)
end do
WRITE(4,*)
!-----
WRITE(4,*)'  AJUSTE DE LA CURVA : '
DO J=1,m
WRITE(4,'(1F18.13)') ys(1,J)
end do
WRITE(4,*)
!-----
CLOSE(unit=4)
!*****
WRITE(*,'(4X,a\)' )'¿DESEA REALIZAR PRONOSTICO..SI=1,..NO=0...? '
READ(*,*)B
IF(B.EQ.1)THEN
WRITE(*,'(4X,a\)' )'HORIZONTE DEL PRONÓSTICO:'
READ(*,*) m
t=1
!-----
WRITE(*,'(4X,a\)' )'          DAME EL ARCHIVO DE DATOS PROYECTADOS:'
READ(*, '(a)') archiv_ent
OPEN(unit=3,file=archiv_ent)
READ(3,*) ((xd(i,j),i=1,n),j=1,m)
CLOSE(unit=3)

```

```

!-----
WRITE(*,'(4X,a\)' )'¿CUENTA CON VALORES REALES..SI=1,..NO=0...? '
READ(*,*)B
IF(B.EQ.1)THEN
WRITE(*,'(4X,a\)' )'DAME EL ARCHIVO DE DATOS REALES DE LA SALIDA:'
READ(*,'(a)') archiv_ent
OPEN(unit=4,file=archiv_ent)
READ(4,*) ((yd(i,j),i=1,1),j=1,m)
CLOSE(unit=4)
ELSE
do i=1,m
yd(1,i)=0
end do
end if
g=2
goto 300
400 continue
!-----
WRITE(*,'(4X,a)' )'CALCULOS FINALIZADOS '
! GRABA DATOS EN ARCHIVO PRONÓSTICO
print*,'DESEA GUARDAR LOS RESULTADOS DEL PRONÓSTICO EN EL ARCHIVO '
READ(*,'(a)') prono_dat
OPEN(unit=4,file=prono_dat)
WRITE(4,'(2x,a,F10.6)' )' ERROR ABSOLUTO: ',se
WRITE(4,*)
WRITE(4,'(2x,a,F10.6)' )' ERROR PORCENTUAL: ',pe
WRITE(4,*)
!-----
WRITE(4,*)' AJUSTE DE LA CURVA : '
DO J=1,m
WRITE(4,'(1F18.13)' ) ys(1,J)
end do
WRITE(4,*)
!-----
WRITE(4,*)' DATOS REALES: '
DO J=1,m
WRITE(4,'(1F18.13)' ) yd(1,J)
end do
WRITE(4,*)
!-----
CLOSE(unit=4)
!-----
else
end if
END

```

“APÉNDICE D”

MANUAL DE OPERACIÓN DEL PROGRAMA DE REGRESIÓN LINEAL.

1. Formar con la información existente los archivos de entrada de la siguiente manera:

- Archivo 1.- “datos.dat”, este archivo debe contener la información de las variables independientes que se utilicen para el ajuste de la curva, por ejemplo:

TEMPERATURA	POBLACIÓN	HUMEDAD
5.35	1639526.8	50.09
8.19	1642819.51	45.57
11.86	1646112.22	39.28
17.53	1649404.93	34.74
21.57	1652697.66	39.48
.	.	.
.	.	.
.	.	.
.	.	.

- Archivo 2.- “dem.dat”, este archivo debe contener la información de la demanda, la cual se utilizará para el ajuste de la curva, por ejemplo.

DEMANDA
672
662
712
771
860
.
.
.
.

- Archivo 1.- “datosp.dat”, este archivo debe contener la información de las variables independientes proyectadas que se utilizan para el calculo del pronóstico, por ejemplo:

TEMPERATURA	POBLACIÓN	HUMEDAD
5.35	1639526.8	50.09
8.19	1642819.51	45.57
11.86	1646112.22	39.28
17.53	1649404.93	34.74
21.57	1652697.66	39.48

Ningún archivo debe contener encabezados y cada columna debe estar separada por espacios.

2. Al ejecutar el programa, éste solicita la siguiente información.
  - Periodos de la demanda.- se debe dar el número de periodos que serán utilizados para ajustar la curva.
  - Variables independientes.- se debe dar el número de variables independientes que se emplean para la simulación.
  - Número de pronósticos.- se proporciona el número de pronosticos que se desea calcular.
3. Así mismos el programa requiere de los siguientes archivos:
  - Archivo de variables independientes.- se debe dar el nombre del archivo “datos.dat”.
  - Archivo de variables dependientes.- se dará el nombre del archivo “dem.dat”.
  - Archivo de variables proyectadas.- se debe dar el nombre del archivo “datosp.dat”.
4. Por último el programa solicita que se de el nombre del archivo en el cual se grabara la información del ajuste de la curva y el pronóstico, así como los parámetros de curva encontrada, el cual contiene la información en los siguientes bloques, separados por renglones:
  - Parámetros de la curva.
  - Ajuste de la curva.
  - Pronóstico.

“APÉNDICE E”

MANUAL DE OPERACIÓN DEL PROGRAMA DEL MÉTODO AUTORREGRESIVO.

1. Formar con la información existente los archivos de entrada de la siguiente manera:

- Archivo 1.- “datos.dat”, este archivo debe contener la matriz de las variables independientes que se utilicen para el ajuste de la curva, además en la primera columna se debe dar ésta con unos, por ejemplo:

	TEMPERATURA	POBLACIÓN	HUMEDAD
1	5.35	1639526.8	50.09
1	8.19	1642819.51	45.57
1	11.86	1646112.22	39.28
1	17.53	1649404.93	34.74
1	21.57	1652697.66	39.48
.	.	.	.
.	.	.	.
.	.	.	.
.	.	.	.

- Archivo 2.- “dem.dat”, este archivo debe contener la información de la demanda, la cual se utilizará para el ajuste de la curva, por ejemplo.

DEMANDA
672
662
712
771
860
.
.
.
.

- Archivo 3.- “datosp.dat”, este archivo debe contener la matriz de las variables independientes proyectadas que se utilizan para el cálculo del pronóstico, al igual que en datos.dat se deba dar en la primera columna con unos, por ejemplo:

	TEMPERATURA	POBLACIÓN	HUMEDAD
1	5.35	1639526.8	50.09
1	8.19	1642819.51	45.57
1	11.86	1646112.22	39.28

1	17.53	1649404.93	34.74
1	21.57	1652697.66	39.48

Ningún archivo no debe contener encabezados y cada columna debe estar separada por espacios.

2. Al ejecutar el programa este solicita la siguiente información.
  - Variables contando la demanda.- se debe dar el número de variables independientes contando la dependiente (demanda).
  - Número de periodos a analizar.- se proporciona el número de periodos utilizados para el ajuste de la curva.
3. Así mismos el programa requiere de los siguientes archivos:
  - Archivo de la matriz de variables.- se debe dar el nombre del archivo “datos.dat”
  - Archivo de la matriz de variables dependientes.- se dará el nombre del archivo “dem.dat”.
  - Archivo de variables a pronostica.- se debe dar el nombre del archivo “datosp.dat”
4. a continuación el programa solicitará:
  - El número de pronósticos a realizar.
  - El nombre del archivo de las variables proyectadas.- aquí se da el archivo datop.dat.
5. Por último el programa solicita que se de el nombre del archivo, en el cual se grabará la información del ajuste de la curva y el pronóstico, así como los parámetros de curva encontrada, el cual contiene la información en los siguientes bloques, separados por renglones:
  - Parámetros de la curva.
  - Ajuste de la curva.
  - Pronóstico.



“APÉNDICE F”

MANUAL DE OPERACIÓN DEL PROGRAMA DE REDES NEURONALES  
ARTIFICIALES.

1. Formar con la información existente los archivos de entrada de la siguiente manera:

- Archivo 1.- datos.dat, este archivo debe contener la información de las variables independientes que se utilicen para el ajuste de la curva, por ejemplo:

TEMPERATURA	POBLACIÓN	HUMEDAD
5.35	1639526.8	50.09
8.19	1642819.51	45.57
11.86	1646112.22	39.28
17.53	1649404.93	34.74
21.57	1652697.66	39.48
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.

Ningun archivo no debe contener encabezados y cada columna debe estar separada por espacios.

- Archivo 2.- “dem.dat”, este archivo debe contener la información de la demanda que se utilicen para el ajuste de la curva, por ejemplo.

DEMANDA
672
662
712
771
860
.
.
.
.
.

- Archivo 3.- “datos.dat”, este archivo debe contener la información de las variables independientes proyectadas que se utilizan para el calculo del pronóstico, por ejemplo:

TEMPERATURA	POBLACIÓN	HUMEDAD
5.35	1639526.8	50.09
8.19	1642819.51	45.57
11.86	1646112.22	39.28
17.53	1649404.93	34.74
21.57	1652697.66	39.48

- Archivo 4.- demp.dat, este archivo debe contener la información de la demanda real si existiera esta información, únicamente se dará esta información cuando se está probando el programa, para calcular el error en el pronóstico, por ejemplo:

DEMANDA
672
662
712
771
860

- Al ejecutar el programa requiere la siguiente información:
  - Valores para el entrenamiento.- se dará el número de periodos que serán utilizados para el entrenamiento de la red.
  - Número de variables de entrada.
  - Número de neuronas en la capa oculta.
  - Número de iteraciones máximas que el programa realizara para el entrenamiento.
  - Factor de aprendizaje.
  - Temperatura.
  - Momento.
  - Tolerancia, a la cual se para el programa.
- El programa, se presenta una pregunta para conocer si la red está entrenada o no, generalmente se entrena la red, con la matriz de pesos con valores muy pequeños.

4. Al seleccionar “0” el programa solicita la siguiente información.
  - Nombre del archivo de datos de entrada.
  - Nombre del archivo de datos de salida. Aquí se proporciona el archivo de la demanda el cual se emplea para la comparación del error e inicio de la retropropagación del error.
5. Cuando la red se entrena de acuerdo a la tolerancia especificada, se proporciona el nombre del archivo para grabar el ajuste, en este archivo se graba la información de los parámetros empleados, matrices de pesos y ajuste de la curva.
6. Posteriormente a este paso y dependiendo si el resultado es favorable, se realiza el pronóstico, para lo cual el programa requiere:
  - Horizonte de tiempo, aquí se proporciona el número de pronósticos que se realizaran.
  - Archivo de datos proyectados, se debe dar el nombre del archivo “datosp.dat”
  - Y si se cuenta con el archivo de datos reales cuando se está en la fase de pruebas se debe seleccionar la opción de datos reales y dar el archivo “demp.dat” de datos reales de la demanda.
5. Por último, el programa solicita que se de el nombre del archivo en el cual se grabara la información del ajuste de la curva y el pronóstico, así como los parámetros de curva encontrada, el cual contiene la información en los siguientes bloques, separados por renglones:
  - Error del pronóstico.
  - Pronóstico.
  - Datos reales (opcional).

## “APÉNDICE G”

### 1 Introducción a las series de tiempo

*Una serie de tiempo es una secuencia cronológica de observaciones respecto a una variable en particular [19].*

Los datos de la serie de tiempo se examinan a menudo con la esperanza de descubrir un patrón histórico que se pueda explotar en la preparación de un pronóstico. Las componentes de una serie de tiempo son [19]:

- *Tendencia*, se refiere a un movimiento ascendente o descendente que caracteriza una serie durante un tiempo establecido.
- *Ciclo*, se refiere a las fluctuaciones arriba y abajo de los valores alrededor de los niveles de la tendencia. Estas fluctuaciones pueden tener duraciones de diversos tamaños.
- *Variaciones estacionales*, son los patrones periódicos en una serie de tiempo que se repiten sobre una base determinada.
- *Fluctuaciones irregulares*, son movimientos erráticos en una serie de tiempo que no siguen ninguna tendencia regular.

### 2 Análisis de las series de tiempo

Los objetivos del análisis de las series de tiempo son varios. Estos objetivos se pueden clasificar como [11][19][21]:

- *La descripción*, se aplica cuando se presenta una serie de tiempo, y el primer paso del análisis es generalmente trazar el diagrama de dispersión para obtener medidas descriptivas simples de sus características principales.
- *La observación*, con la observación de los datos a menudo es posible determinar el modelo que se necesitara para el análisis de la serie de tiempo.
- *La explicación*, se emplea cuando en las observaciones se adquieren dos o más variables, y puede ser posible utilizar la variación en una serie de tiempo para explicar la variación de la otra.

- *La predicción*, dada una serie de tiempo observada, se pueden estimar los valores futuros de la serie.
- *El control*, es aplicado cuando se genera una serie de tiempo que mide un proceso, y el objetivo del análisis puede ser, utilizar el análisis realizado para corregir o mantener dentro de un valor a dicho proceso.

### 3 Análisis de la serie con datos estacionales

En el análisis de una serie de tiempo a cierto plazo, con datos estacionales, se recomienda comenzar calculando los promedios (anuales, trimestrales según sea el horizonte) sucesivos pues éstos proporcionan una descripción simple de la tendencia. Un acercamiento de este tipo es a veces adecuado, pero un acercamiento más sofisticado será utilizar las siguientes técnicas [21][26]:

- El método tradicional de la curva estandarizada, consiste en analizar los datos no estacionales que tengan una tendencia, particularmente de los datos anuales, representando una función simple.
- El procedimiento del filtrando, de una tendencia es utilizar un filtro lineal como se representa en la figura 2.1. que convierta una serie de tiempo,  $\{x_t\}$ , en otra,  $\{y_t\}$ , lo cual se representa por la siguiente ecuación lineal.

$$y_t = \sum_{r=-q}^{+s} a_r x_{t+r} \quad (A.G.1)$$

Donde  $\{a_r\}$  es un sistema de pesos. Para alisar las irregularidades locales y estimar la media local.



Figura A.G.1. Representación del filtrado de una serie.

#### 4 Transformaciones

Cuando existen series con datos que no representan perfectamente las componentes de las series de tiempo, será necesario transformar los datos, esto hará que la serie pueda ser mejor apreciada, las funciones de transformación más conocidas son los logaritmos o raíces cuadradas u otra función de transferencia que se adapte a nuestros requerimientos. Las razones principales de hacer una transformación son [18][21][26]:

- Estabilizar la variación de los valores de la serie.
- Hacer una adición estacionaria del efecto, si hay una tendencia en la serie.
- Hacer que los datos sean normalmente distribuidos.

#### 5 Filtros en series

Un procedimiento de alisamiento se realiza a menudo en dos o más etapas, de modo que se tenga el efecto de varios filtros lineales en serie. Por ejemplo, dos filtros en serie pueden ser representados en la figura 2.2 [21]:




Figura A.G.2. Representación de dos filtros en serie.

#### 6 Correlación

El concepto de la correlación entre dos variables es directo es decir la relación mutua entre dos variables, describe la tendencia de una de ellas si se presenta un cambio en una la otra lo manifiesta, el grado de correlación, es conocido como *coeficiente de correlación* [12][18][26].

Este coeficiente se da por:

$$\rho(X, Y) = \frac{Cov(X, Y)}{\sigma_x \sigma_y} \quad (A.G.2)$$

Donde:

$$Cov(X, Y) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad (A.G.3)$$

$\sigma_x$  y  $\sigma_y$  representan la desviación estándar de  $X$  y  $Y$ , respectivamente.

El coeficiente de correlación se presenta normalizado siendo independiente de las escalas de las variables involucradas, por lo tanto este nivel siempre caerá entre -1 y +1, a lo que una correlación positiva indica que las variables se mueven en la misma dirección, mientras que una negativa indica que las variables se mueven en direcciones opuestas [12].

El *coeficiente de autocorrelación* es similar a un coeficiente correlación con la excepción de que describe la relación mutua entre valores de la misma variable, pero en diferentes periodos, la autorrelación proporciona información importante acerca de la estructura de un conjunto de datos completamente aleatorios la autorrelación entre valores sucesivos estará cerca de cero o igual a cero, pero los valores de datos con un grado alto de estacionalidad o series demasiado cíclicas estarán sumamente autorrelacionados [11][26].